

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ESTUDO DA INFLUÊNCIA DE BASES DE CASOS EM REDES IAC
(INTERACTIVE ACTIVATION AND COMPETITION) NA
IMPLEMENTAÇÃO DE SISTEMAS ESPECIALISTAS

DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE DE SANTA
CATARINA PARA A OBTENÇÃO DE GRAU DE MESTRE EM
ENGENHARIA ELÉTRICA

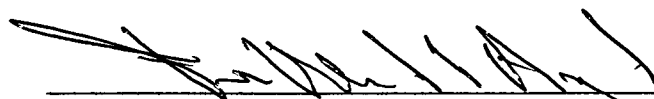
NANCY AKEMI SIGAKI

FLORIANÓPOLIS, FEVEREIRO 1997.

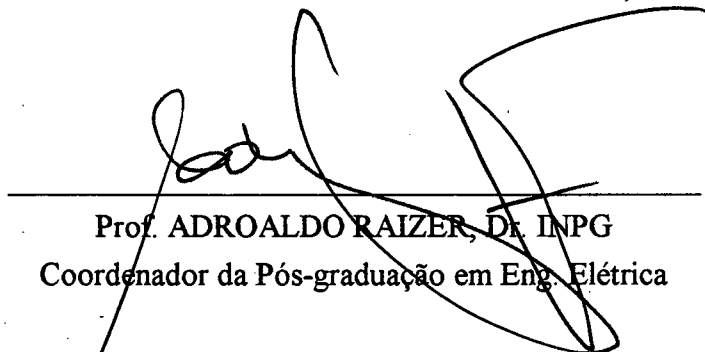
NANCY AKEMI SIGAKI

ESTUDO DA INFLUÊNCIA DE BASES DE CASOS EM REDES IAC
(INTERACTIVE ACTIVATION AND COMPETITION) NA IMPLEMENTAÇÃO DE
SISTEMAS ESPECIALISTAS

Esta dissertação foi julgada adequada para a obtenção do título de Mestre, especialidade em Engenharia Elétrica e aprovada em sua forma final pelo Programa de Pós-graduação em Engenharia Elétrica.



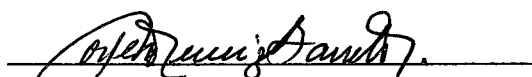
Prof. FERNANDO MENDES DE AZEVEDO, Dr.



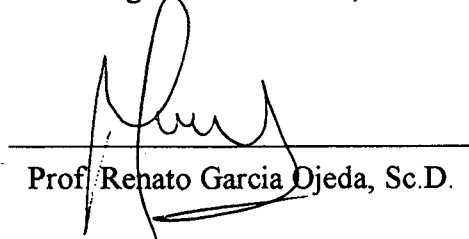
Prof. ADROALDO RAIZER, Dr. INPG

Coordenador da Pós-graduação em Eng. Elétrica

Banca Examinadora



Prof. Jorge Muniz Barreto, D.Sc.A.



Prof. Renato Garcia Ojeda, Sc.D.



Prof. Marcelo Ricardo Stemmer, D.Sc.

*Ao meu marido Paulo Henrique e
ao meu filho Fábio Hideki.*

AGRADECIMENTOS

Ao Prof. Dr. Fernando Mendes de Azevedo pela valiosa colaboração na orientação deste trabalho.

Aos amigos do GPEB, que fiz durante o curso e, em especial agradecimento, à Lourdes Mattos Brasil, ao Roberto Célio Limão e ao John O. Wisbeck que, de alguma forma contribuíram para o desempenho deste trabalho.

Ao meu marido Paulo Henrique da Rocha que sempre me incentivou e apoiou nas horas mais difíceis durante o desenvolvimento da tese. E ao meu filho Fábio Hideki Sigaki da Rocha por dar um novo significado para a minha vida.

BIOGRAFIA DA AUTORA



NANCY AKEMI SIGAKI, nascida em Guarulhos - São Paulo em agosto de 1969. Formado em Engenharia Elétrica pela Universidade Estadual Paulista - Campus de Guaratinguetá em dezembro de 1994. Em março de 1995, ingressou no Curso

de Pós-Graduação, a nível de mestrado, na Universidade Federal de Santa Catarina onde fez parte do Grupo de Pesquisas em Engenharia Biomédica, sob a orientação do Prof. Dr. Fernando Mendes de Azevedo. Concretizou a tese de mestrado em fevereiro de 1997. Atualmente, suas principais áreas de interesse são Inteligência Artificial, instrumentação eletrônica e sensoriamento a fibra óptica.

SUMÁRIO

SUMÁRIO.....	i
PUBLICAÇÕES	iii
LISTA DE FIGURAS.....	iv
RESUMO	vii
ABSTRACT	viii
CAPÍTULO 1: INTRODUÇÃO	1
1.1 - OBJETIVOS	1
1.2 - JUSTIFICATIVA	2
1.3 - INTRODUÇÃO AOS SE E MOTIVAÇÃO	3
CAPÍTULO 2 : REDES NEURAIS ARTIFICIAIS.....	9
2.1 - INTRODUÇÃO	9
2.1.1 - Morfologia do Neurônio Biológico.....	10
2.1.2 - Modelo Geral de Neurônio	12
2.1.3 - Topologia de Redes Neurais Artificiais	14
2.1.3.1 - Redes Diretas (Feedforward).....	14
2.1.3.1.1 - Redes com uma única camada (<i>single-layer</i>).....	15
2.1.3.1.2 - Redes multi-camadas (<i>multilayer</i>)	15
2.1.3.2 - Redes com realimentação (<i>Feedback</i>).....	16
2.1.4- Aprendizado em Redes Neurais	16
2.1.4.1 - Aprendizado supervisionado.....	17
2.1.4.2 - Aprendizado não supervisionado	17
2.1.5 - Regras de Aprendizado.....	18
2.1.5.1 - Regra de Hebb.....	18

2.1.5.2 - Regra Delta	19
2.1.5.3 - Regra Backpropagation	19
2.1.6 - Alguns Modelos de Redes Neurais	21
2.2 - REDES IAC	21
2.2.1 - Modelo de Rumelhart e McClelland	22
2.2.2 - Modelo de Grossberg	26
2.2.3 - Modelo de Azevedo	27
CAPÍTULO 3: O SISTEMA COMPUTACIONAL	29
3.1 - INTRODUÇÃO	29
3.1.1 - Módulo 1 - Escolha do Modelo de Redes Conexionistas	30
3.1.2 - Módulo 2 - Escolha das Versões	31
3.1.3 - Módulo 3 - Análise dos Resultados (Gráficos)	35
3.2 - VALIDAÇÃO DO SISTEMA COMPUTACIONAL PROPOSTO	36
CAPÍTULO 4 - ESTUDO DO APRENDIZADO BASEADO EM CASOS	42
4.1 - INTRODUÇÃO	42
4.2 - ESTUDO DE CASO	43
4.3 - METODOLOGIA	48
CAPÍTULO 5 - SIMULAÇÕES	52
5.1 - INTRODUÇÃO	52
5.2 - SIMULAÇÕES - SISTEMA "REDUZIDO"	52
5.3 - SIMULAÇÕES - SISTEMA "COMPLETO"	62
CAPÍTULO 6: DISCUSSÕES E CONCLUSÕES	74
BIBLIOGRAFIA	76

LISTA DE FIGURAS

2.1 Neurônio biológico	11
2.2 Modelo de Neurônio [Day90].....	13
2.3 Rede <i>feedforward</i> com três camadas.....	15
2.4 Redes <i>feedback</i> (Com realimentação).....	16
2.5 Modelo de Rumelhart e McClelland. O grupo de verde representa o grupo escondido e os demais representam os grupos visíveis.....	23
2.6 Gráfico dos parâmetros	25
2.7 Modelo de Azevedo.....	27
3.1 Tela de apresentação do sistema.....	30
3.2 Tela da escolha do modelo de redes conexionistas.....	31
3.3 Tela apresentando a estrutura de uma Rede IAC.....	32
3.4 Tela de entrada do número de ciclos.....	34
3.5 Programa em execução.....	34
3.6 Gráficos dos neurônios pré-definidos.....	36
3.7 Tela final de um caso particular da base de dados.....	37
3.8 Paciente inicialmente com dois sintomas: artralgia e artrite.....	38
3.9 Diagnóstico final do exemplo 2.....	39
3.10 Transitório dos níveis de ativação das duas doenças.....	40
3.11 Paciente inicialmente com dois sintomas: mialgia e manifestação renal.....	40
3.12 Diagnóstico final do exemplo 3.....	41
3.13 Transiente dos níveis de ativação das duas doenças.....	41
4.1 Diagrama de blocos do programa.....	49
5.1 Sist. "Reduzido", Ex. 1 - Paciente apresentando artralgia, artrite e mãos reumáticas após 40 ciclos.....	55
5.2 Sist. "Reduzido", Ex. 1 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.....	56
5.3 Sist. "Reduzido", Ex. 1 - Introdução de um caso real para cada doença.....	56

5.4 Sist. "Reduzido", Ex. 1 - Introdução de três casos reais para cada doença.....	56
5.5 Sist. "Reduzido", Ex. 1 - Introdução de seis casos reais para cada doença.....	57
5.6 Sist. "Reduzido", Ex. 2 - Paciente apresentando os sintomas mialgia, manifestação renal e rigidez matinal após 40 ciclos.....	58
5.7 Sist. "Reduzido", Ex. 2 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.....	58
5.8 Sist. "Reduzido", Ex. 2 - Introdução de dois casos reais para cada doença.....	59
5.9 Sist. "Reduzido", Ex. 2 - Introdução de quatro casos reais para cada doença.....	59
5.10 Sist. "Reduzido", Ex. 2 - Introdução de seis casos reais para cada doença.....	59
5.11 Sist. "Reduzido", Ex. 3 - Paciente apresentando os sintomas artralgia, artrite e erupção tipo borboleta após 40 ciclos.....	60
5.12 Sist. "Reduzido", Ex. 3 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.....	61
5.13 Sist. "Reduzido", Ex. 3 - Introdução de dois casos reais para cada doença.....	61
5.14 Sist. "Reduzido", Ex. 3 - Introdução de quatro casos reais para cada doença.....	61
5.15 Sist. "Reduzido", Ex. 3 - Introdução de seis casos reais para cada doença.....	62
5.16 Sist. "completo", Ex.1 - Paciente apresentando os sintomas artralgia, artrite e tophi após 60 ciclos.....	64
5.17 Sist. "completo", Ex.1 - Transitório do nível de ativação sem a introdução de casos reais clínicos.....	65
5.18 Sist. "completo", Ex.1 - Introdução de dois casos reais para cada doença.....	65
5.19 Sist. "completo", Ex.1 - Introdução de quatro casos reais para cada doença.....	66
5.20 Sist. "completo", Ex.1 - Introdução de seis casos reais para cada doença.....	66
5.21 Sist. "completo", Ex.2 - Paciente apresentando os sintomas artralgia, artrite e mãos reumáticas após 60 ciclos.....	67
5.22 Sist. "completo", Ex.2 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.....	67
5.23 Sist. "completo", Ex.2 - Introdução de dois casos reais para cada doença.....	68
5.24 Sist. "completo", Ex.2 - Introdução de quatro casos reais para cada doença.....	68
5.25 Sist. "completo", Ex.2 - Introdução de seis casos reais para cada doença.....	69

5.26 Sist. "completo", Ex.3 - Paciente apresentando os sintomas artrite, artralgia e lesão psoriática após 60 ciclos.....	69
5.27 Sist. "completo", Ex.3 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.....	70
5.28 Sist. "completo", Ex.3 - Introdução de três casos reais para cada doença.....	70
5.29 Sist. "completo", Ex.3 - Introdução de seis casos reais para cada doença.....	71
5.30 Sist. "completo", Ex.4 - Paciente apresentando os sintomas artrite, artralgia e erupção tipo borboleta após 60 ciclos.....	71
5.31 Sist. "completo", Ex.4 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.....	72
5.33 Sist. "completo", Ex.4 - Introdução de dois casos reais para cada doença.....	72
5.34 Sist. "completo", Ex.4 - Introdução de quatro casos reais para cada doença.....	73
5.35 Sist. "completo", Ex.4 - Introdução de seis casos reais para cada doença.....	73

RESUMO

Neste trabalho é estudado o problema do aprendizado (baseado em casos) em redes conexionistas IAC (*Interactive Activation and Competition*). Esta arquitetura de redes foi, primeiramente, proposta por Rumelhart e McClelland [Rum86] e, também, estudada por Grossberg [Rum86]. O modo básico de aprendizado, nestes tipos de redes, pode ser classificado como “*Rote Learning*”. Ou seja, através de um trabalho de “Engenharia de Conexões” (semelhante ao procedimento de “Engenharia de Conhecimento” em Sistemas Especialistas Simbólicos) os pesos das conexões são determinados “a priori” e armazenados na estrutura da rede, não havendo, portanto, uma fase de “real” aprendizado. Neste sentido, foi desenvolvido um *software* utilizando linguagem *Visual Basic* (para ter uma melhor interface com o usuário), para a implementação da rede IAC, contendo as versões de Rumelhart e McClelland, de Grossberg e a versão proposta por de Azevedo. Para validar o sistema e exemplificar o estudo da abordagem, foi construído um Sistema de Apoio a Decisão na Área Médica, utilizando um problema de Diagnóstico Diferencial em Reumatologia. Para validar o sistema, foi realizada um estudo comparativo desta implementação usando como referência o sistema desenvolvido por de Azevedo. A seguir foi estudado o comportamento deste tipo de redes quando considerados casos reais clínicos diagnosticados por um especialista da área em comparação com uma rede contendo somente as relações entre doenças e sintomas. Discute-se, finalmente, o desempenho comparativo das duas redes: aquela contendo somente as relações doenças sintomas e aquela contendo, também, os casos clínicos reais.

Palavras chaves: Engenharia de Conexões, Redes Conexionistas IAC, Sistemas Especialistas, Regra de Aprendizado, Raciocínio Baseado em Casos.

Study of the influence of case based on IAC (Interactive Activation and Competition) Neural Network to implement Expert Systems

ABSTRACT

This work presents a study of learning (case based) in IAC (Interactive Activation and Competition) connectionist model. The IAC neural network approach was proposed by McClelland and Rumelhart. Models of this nature have been studied by Grossberg. In this kind of neural network, the basic mode of learning, may be classified as "Rote Learning", that is, by a Connection Engineering work (similar to procedure of knowledge engineer in Symbolic Expert Systems) the connection weights, are set "a priori" and stored on the neural network structure. Thus, there is not a real learning phase. In the way, to implement the system, a program was written in Visual Basic in a windows environment. The implementation of this paradigm takes into consideration the Rumelhart, Grossberg and de Azevedo versions. An example of Differential Diagnosis in Rheumatology is used to validate of the system and to study the learning performance. Following, it was studied the behavior in this kind of network, when considered real clinical cases, diagnosed by a expert, in order to compare with a network formed only by the symptoms and disease relations. Finally, it is discuss the performance about the network formed only symptoms and diseases relations and the network formed also of the real clinical cases.

Key-words: Connection Engineering, IAC Neural Network, Expert Systems, Rote Learning, Case Based Reasoning.

CAPÍTULO 1: INTRODUÇÃO

1.1 - Objetivos

O objetivo deste trabalho consiste em estudar o problema do aprendizado (baseado em casos) no modelo de redes conexionistas IAC (*Interactive Activation and Competition*), proposta por Rumelhart e McClelland [Rum86], também, estudada por Grossberg [Rum86]. O modo básico de aprendizado, nestes tipos de redes, pode ser classificado como "*Rote Learning*", ou seja, os pesos das conexões são armazenados na estrutura do sistema. Pretende-se, entanto, estudar o desempenho do "aprendizado" da rede em função dos casos através da inclusão de um grupo de casos clínicos diagnosticados por um médico. Este grupo de casos conhecidos, representa uma base de conhecimento adicional para o sistema. É especulado que a presença de casos reais clínicos conhecidos, na estrutura da rede, deveria melhorar o seu desempenho quando comparado com o desempenho de uma rede contendo somente as relações doenças/sintomas. Quanto maior o número de casos conhecidos dentro deste grupo, se eles são capazes de representar o universo de possibilidades, melhor seria o desempenho da rede. Isto é semelhante aos procedimentos de CBR (*Case Based Reasoning*), onde o sistema procura, nos casos resolvidos anteriormente, um caso semelhante ao problema apresentado e, com base na solução dada ao caso anterior, procura modificá-la para solucionar o presente problema. Para este estudo considerou-se o desenvolvimento de um protótipo de Sistema Especialista para Auxílio ao Diagnóstico Médico utilizando um problema de Diagnóstico Diferencial em Reumatologia.

O trabalho apresenta, também, como segundo objetivo o desenvolvimento de um sistema computacional para a implementação do modelo IAC, nas três versões. Este sistema deve resolver, ainda, muitas das limitações encontradas no pacote de *software* original proposto por McClelland e Rumelhart [Rum86]. Mais ainda, o sistema deve permitir que, no futuro, módulos contendo outros modelos de redes conexionistas, sejam recursivas ou *feedforward*, que possam a ele serem acrescentados.

1.2 - Justificativa

Os primeiros Sistemas Especialistas utilizavam como tecnologia de desenvolvimento técnicas de manipulação simbólica. Através de um conjunto de regras, que é definida como base de conhecimento, e uma máquina de inferência, muitos SE's simbólicos foram implementados. Os mais populares foram o Mycin [Short76] e o Dendral [Fei88] dentre outros. Entretanto, pode-se dizer que estes sistemas apresentam alguns problemas, apesar de que muitos deles apresentaram e continuam apresentando desempenho considerado como razoável. Tais referidos problemas são, por exemplo, problemas de inconsistências na base de conhecimento, informações incompletas, tratamento de imprecisões e incertezas, representação do conhecimento e outros. Mais, ainda, pode-se dizer que tais sistemas apresentavam uma baixa inspiração biológica.

Mais recentemente, com o crescimento do Paradigma Conexcionista da Inteligência Artificial, surgiu uma nova classe de Sistemas Especialistas, aqueles baseados em redes neurais artificiais, sendo o trabalho de Gallant [Gal88] um dos pioneiros. Estes sistemas utilizavam, primeiramente, uma rede neural *feedforward* estática, treinada via algoritmo "*backpropagation*" com um conjunto de casos entrada/saída. Era então, conjecturado, que devido as capacidades de aprendizado e de interpolação (ou generalização) das redes, elas, depois de treinadas, seriam capazes de dar respostas consideradas razoáveis para entradas não consideradas no conjunto de treinamento. O grande problema apontado para este tipo de implementação é a dificuldade de se extrair uma explicação do "raciocínio" seguido pela rede para chegar a uma conclusão. Mas, do ponto de vista de inspiração biológica, estes tipos de SE's, também ainda estavam longe de representar o funcionamento de um cérebro biológico, pois este é um sistema dinâmico altamente complexo.

Muitas implementações neste sentido foram consideradas em diversas áreas do conhecimento. Só na implementação de Sistemas na Área Médica podem-se citar trabalhos em áreas tão diferentes como neurologia [Appol90], psiquiatria [Muls88], oftalmologia [Cof89], endocrinologia [Smith88], cardiologia [Har91], gastroenterologia [Yoshi89][Eber90], dermatologia [Yoon88], neonatologia [McMil89], cirurgia [Pham89], ortopedia [Bounds90], oncologia [Hudson88] e radiologia [Boone90]. No Grupo de Pesquisas em Engenharia Biomédica do Departamento de Engenharia Elétrica

da Universidade Federal de Santa Catarina, alguns trabalhos têm sido feitos, também, nesta área, usando tanto técnicas simbólicas quanto conexionistas e, mesmo, híbridas. Entre eles podem-se citar: [Gar90] [Gar92] [Niev90] [Lop95] [Nas95] [Pass95] [Bar93] [Azev91] [Pe97] [Lin97] [Bra97] [Ram95].

No caso dos modelos IAC (*Interactive Activation and Competition*), a inspiração biológica é bem mais forte que nos dois casos anteriores. Este tipo de arquitetura é uma rede dinâmica, que trabalha através de um mecanismo de ativação e interação, onde todos os neurônios interagem com todos os outros, com ligações tanto excitatórias como inibitórias, de modo a encontrar um ponto de equilíbrio, que representaria a solução para um dado problema. Um sistema como este pode ser utilizado para o desenvolvimento de SE's, como demonstrado por de Azevedo em [Azev91][Bar93]. Com a vantagem de tentar abstrair um modelo mais realista do funcionamento do cérebro biológico.

1.3 - Introdução aos SE e Motivação

Inteligência Artificial (IA) é um termo que possui muitas definições. Para chegar a uma definição aceitável devemos, primeiramente, entender o tipo de problema resolvido por esta área. Segundo Turban [Turb92], os especialistas concordam que a IA se preocupa com dois problemas básicos. O primeiro envolve estudos do processamento humano (para entender o que é a inteligência) e o segundo, com a representação de processos via máquina (computador, robôs, etc).

Ainda segundo Turban [Turb92] uma definição de IA é a de que: "Inteligência Artificial é o comportamento de uma máquina que, se realizado por um ser humano, poderia ser chamado de comportamento inteligente" [Turb92]. Uma outra definição provém de [Rich84]: "Inteligência Artificial é o estudo de como fazer os computadores realizarem tarefas que, até o momento, pessoas fazem melhor". Mark Fox da Universidade de Carnegie-Mellon diz que IA é basicamente uma teoria de como a mente humana trabalha [Turb92].

Para explorar o significado do termo "comportamento inteligente", são consideradas várias habilidades quais sejam:

- Aprender ou entender através da experiência;
- Fazer com que tenham sentido as mensagens ambíguas e contraditórias;
- Responder rapidamente a uma nova situação;
- Usar a razão para se responder a um problema;
- Lidar com situações complexas;
- Adquirir e aplicar o conhecimento.

Embora a meta final de IA seja a capacidade da construção de produtos comerciais utilizando-se de tecnologias de IA, ou seja apresentando um comportamento minimamente semelhante àquele apresentado por sistemas biológicos, esta meta ainda se encontra longe de atingir a maioria das habilidades listadas acima.

Um teste interessante para determinar se o computador, exibe um comportamento inteligente, foi proposto por Alan Turing (mencionado em [Hof81]), e é chamado de “*Turing Test*”. De acordo com este teste, o computador poderia ser considerado inteligente somente quando um interrogador humano, conversando com um ser humano e um computador não vistos, não pudesse determinar quem é quem.

Apesar de restringir o comportamento inteligente a seres humanos, e apesar de supor o uso de uma linguagem humana conhecida, o teste de Turing é amplamente aceito como um teste de inteligência [Bar96].

Grande parte do trabalho inicialmente feito na área de Inteligência Artificial (IA) focalizava tarefas formais, tais como jogos e demonstração de teoremas. Uma outra incursão pioneira pela IA enfocou a solução de problemas de raciocínio de senso comum. Com o avanço das pesquisas em IA, foram desenvolvidas técnicas para a manipulação de uma maior quantidade de conhecimentos, houve progressos nas tarefas de raciocínio de senso comum, e novas tarefas puderam ser experimentadas.

As áreas de aplicação onde atualmente a IA está mais florescendo como disciplina prática são basicamente os domínios que exigem apenas conhecimento especializado, sem o auxílio do conhecimento de senso comum [Rich93]. Existem milhares de programas chamados Sistemas Especialistas. Cada um destes sistemas tenta resolver parcial, ou talvez totalmente, um problema prático num domínio restrito do conhecimento.

Sistemas Especialistas (SE) são sistemas capazes de solucionar tarefas específicas, imitando a capacidade dos seres humanos (ou máquinas especializadas) em resolver determinados problemas num campo de conhecimento restrito [Azev93].

Os primeiros Sistemas Especialistas (SE) surgiram na década de 70. Entre os que mais se destacaram são o Mycin [Short76], um sistema para detecção e diagnóstico de doenças infecciosas, e o Prospector [Dud79], sistema para dar suporte a geólogos na exploração mineral. Existem também aplicações em muitas outras áreas de conhecimento. Há sistemas no campo da matemática, onde se podem provar teoremas ou efetuar derivação e integração formal; na química, onde o estudo de novos compostos químicos pode ser facilitado; no ensino em geral, podendo o aluno aprofundar seus conhecimentos abordando sistemas de sua área específica. Os SE utilizam técnicas de Inteligência Artificial (IA) e bases de conhecimentos, para solucionar problemas que normalmente são solucionados por especialistas humanos.

Um grande progresso foi feito na direção do desenvolvimento de *shells* genéricos de sistemas especialistas, facilitando o esforço de programação. Assim, uma aplicação pode ser projetada, implementada e testada em menos de um ano [Sab93][Hell91]. O *shell* é somente parte do sistema especialista. Por exemplo, quando os criadores do MYCIN terminaram seu trabalho perceberam que haviam duas partes distintas no sistema: a base de conhecimentos específica da área de diagnóstico médico e a parte do mecanismo de inferência, gerenciado do sistema. Esta distinção os levou a disponibilizar o EMYCIN que se tornou o precursor dos *shells* para o desenvolvimento de sistemas especialistas [Harm88][Sab93].

Sistemas Especialistas são utilizados em diversas aplicações tais como: projetos auxiliado por computador (XCON especifica a configuração de computadores), interpretação de dados, análise científica, diagnóstico médico, análise financeira, podendo ser de manipulação tanto simbólica como conexionista.

No início a tecnologia disponível para a implementação do SE era a manipulação simbólica. O conjunto de regras é definido como Base de Conhecimento. É muito difícil de obter conjunto de regras adequadas de especialistas humanos, pois em muitas áreas, os especialistas não são capazes de articular o conhecimento para atingir a solução de um dado problema. Muitas vezes os especialistas têm dificuldades de explicar como eles chegaram a uma dada resposta. Existem ainda problemas de multiplicidade de

especialistas, pois diferentes especialistas apresentam, muitas vezes, diferentes explicações para suas decisões, podendo até discordarem na decisão final [Azev93].

Além disso, SE tradicionais encontram dificuldades na solução de muitos problemas na vida real, devido a suas inconsistências, tratamento de imprecisões e incertezas, representação do conhecimento e baixa inspiração biológica.

Uma possível resposta para tal limitação está no uso de lógica nebulosa (*fuzzy logic*) que é considerada por muitos pesquisadores como uma ferramenta importante na construção de SE, permitindo lidar como uma imprecisão e incerteza freqüentemente associadas ao raciocínio humano. De acordo com Zadeh [Zad88], na maioria dos casos a incerteza pode ser creditada ao fato de que os elementos básicos no pensamento humano não são números, mas rótulos de conjuntos nebulosos, isto é, classes de objetos nos quais a transição da pertinência para a não-pertinência é gradual em vez de abrupta.

Outra resposta consiste no uso da abordagem *Case Based Reasoning* (CBR). Neste tipo de sistema, a filosofia baseia-se em evidências de que humanos utilizam-se de casos passados, armazenados na memória, quando resolvem certos problemas. Ou seja, adaptam-se soluções conhecidas, de casos antigos identificados como similares, ao da situação atual.

É possível identificar dois tipos de domínio, onde os SE podem atuar, que são: domínio artificial e o domínio natural [Azev93].

Um exemplo de domínio artificial é configurar um sistema computacional. O funcionamento do sistema é considerado conhecido, pois ele é feito pelo homem (*man made*). Em se tratando de Diagnóstico Médico, que é considerado de domínio natural, pois trata-se de um fenômeno natural como uma doença, o funcionamento é conhecido somente parcialmente, como resultado de muita pesquisa e, além disso, a maioria do conhecimento deriva de casos particulares observados. No primeiro caso, são utilizadas regras do tipo Se...Então...Senão. Entretanto, no segundo caso, como o conhecimento é parcial e intrinsecamente impreciso, é difícil traduzir em forma de regras. Os médicos utilizam muito a experiência e o sentimento para resolver seus problemas. No entanto, para se construir um SE para Diagnóstico Médico, algumas regras devem existir. Se os especialistas não podem articular regras apropriadas, então eles podem, seguramente, fornecer exemplos de suas próprias decisões, sendo possível inferir regras, a partir destes exemplos [Azev93]. Estes exemplos, inclusive, podem ser utilizados para o treinamento de uma Rede Neural Artificial.

Redes Neurais Artificiais (RNA) constituem-se em outra técnica de representação do conhecimento em Inteligência Artificial, podendo ser considerado como um bom paradigma para implementar SE. O uso destes modelos é recente e, principalmente, experimental, mas muitos resultados promissores têm sido obtidos nos últimos anos.

As Redes Neurais que formam os chamados Sistemas Conexionistas [Cau91], procuram imitar a organização paralela do cérebro, com as propriedades computacionais de paralelismo real e processamento distribuído.

RNA são representadas através de uma grande quantidade de unidades. Estas unidades possuem características de neurônios biológicos. Isto significa que cada unidade possui várias entradas, podendo ser tanto excitatórias ou inibitórias. Os valores das entradas são combinados por uma soma ponderada gerando, em seguida, uma saída. Esta saída pode estar ligada a entrada de outro neurônio. Portanto, a rede se caracteriza por unidades (neurônios) e pela maneira como elas estão conectadas (topologia). Algoritmos são usados, então, para mudar os pesos das conexões (regra de aprendizado). O efeito geral destes três aspectos constitui o Paradigma Neural da Inteligência Artificial [Baen92].

Os sistemas especialistas connexionistas têm, geralmente, como objetivo resolver tarefas classificatórias. Classificação é uma poderosa estratégia humana para organizar o conhecimento, fundamentando muitos domínios de problema tais como diagnósticos, predição, monitoração, interpretação, seleção, etc. Resolver um problema classificatório consiste em alocar um objeto ou um evento, a uma ou mais dentre diversas categorias pré-definidas. Isto é feito pelo sistema especialista connexionista computando o grau de similaridade (pertinência) do objeto sob análise a cada uma das categorias prototípicas definidas no sistema [Mach92].

As RNAs não possuem a facilidade de explanação de seu raciocínio, ficando associado seu funcionamento ao de uma caixa preta [Hart90]. Com efeito, como o conhecimento fica distribuído pelas conexões, torna-se mais complexo que no caso simbólico. Entretanto existem algumas propostas para minimizar este problema [Gal88].

Na área de diagnóstico médico, a topologia mais utilizada é a rede estática (*feedforward*), multicamada, treinada com algoritmo de aprendizado *backpropagation*. Esta rede é não-linear e não existem *loops* de realimentação. Mas estes tipos de rede estão muito longe de representar o funcionamento de um cérebro biológico, pois o

cérebro é um sistema dinâmico altamente complexo. Além disso, existe evidência de que o algoritmo *backpropagation* não tenha inspiração biológica.

Neste trabalho seguimos uma abordagem diferente. Propõe-se aqui, a utilização da arquitetura IAC (*Interactive Activation and Competition*) que é uma rede recursiva e também está mais próxima da representação do funcionamento do cérebro biológico. Estes modelos de rede têm sido sugeridos por Barreto e de Azevedo como utilizáveis na implementação de Sistemas Especialistas, especialmente, na Área Médica, e tem apresentado bons resultados [Bar93][Azev91a][Azev91b]. A idéia é a exploração dos mecanismos de "ativação interativa e competição", característicos destes modelos, de forma a imitar o raciocínio de um especialista de domínio em contraposição aos Sistemas Especialistas Conexionistas tradicionais que têm sido implementados utilizando-se de uma rede estática treinada com um conjunto de exemplos.

1.4 - Estrutura do trabalho

Neste capítulo foram vistos os objetivos e a justificativa do trabalho. Além disso, foi feita uma introdução de Sistemas Especialistas, bem como a motivação de se desenvolver tal sistema.

O capítulo a seguir (Capítulo 2) aborda a respeito de redes neurais e, em seguida, com mais detalhes, a rede IAC nas versões de Rumelhart e McClelland, Grossberg e de Azevedo.

O sistema computacional foi desenvolvido conforme será visto no capítulo 3, para implementar o sistema especialista contendo as três versões vistas no capítulo anterior.

Uma vez desenvolvido o *software*, foi feito um estudo de casos, visto no capítulo 4, bem como a metodologia seguida neste trabalho.

As simulações e os resultados obtidos podem ser vistos no capítulo 5.

E, finalmente, as conclusões e discussões do trabalho são feitas no capítulo 6.

CAPÍTULO 2 : Redes Neurais Artificiais

2.1 - Introdução

Por muitas décadas tem sido uma meta da ciência e da engenharia desenvolver máquinas inteligentes. Estas máquinas foram antevistas para desempenhar tarefas tediosas, repetitivas, perigosas e incômodas, com o intuito de que os seres humanos pudessem dedicar mais de seu tempo a atividades de lazer, as artes e outras atividades de produção intelectual, usufruindo, portanto de uma melhor qualidade de vida. Muitas Disciplinas e Teorias têm surgido, nas últimas décadas, procurando criar uma base para o projeto e/ou construção de tais máquinas. Muitas destas estão interrelacionadas e/ou podem ser consideradas como um subconjunto de outras. Entre elas podem-se citar: Cibernética (Ashby, 1957; Wiener, 1948), Aprendizado de Máquina (Nilsson, 1965), Estudo dos Automata (Shannon & McCarthy, 1956; Tsetlin, 1973), Biônica (WADD, 1960; Gawronski, 1971), Biofísica Matemática (Rashevsky, 1948), Teoria Geral de Sistemas (Bertalanffy, 1968), Sistemas Auto-Organizados (Yovitz & Cameron, 1960; Yovitz, Jacobi & Goldstein, 1962), Inteligência Artificial (Minsky, 1961; Barr & Feigenbaum, 1981), Ciências Cognitivas (Rumelhart & McClelland, 1986) e Redes Neurais Artificiais (McCulloch & Pitts, 1943) [Simp90].

Muitas destas disciplinas e teorias deram frutos. Outras mantiveram-se, até o momento, a nível teórico. Talvez o mais importante desenvolvimento na direção da automatização destas supra referidas tarefas repetitivas, tediosas, etc, tenha sido o surgimento dos computadores digitais. Estes, por sua vez, causaram uma revolução na nossa sociedade, nos últimos vinte anos. No entanto, apesar do desenvolvimento de computadores digitais cada vez menores, mais baratos, mais potentes, com melhor desempenho e da possibilidade, hoje muito explorada e tornada realidade, da ligação desses computadores em redes que se ligam a outras redes formando uma verdadeira teia de redes mundial, os computadores digitais, também apresentam limitações. Além disto, existem tarefas que não são apropriadas para serem executadas ou resolvidas por computadores deste tipo. Para maiores detalhes veja os conceitos e exemplos de tarefas

baseadas em conhecimentos e tarefas baseadas em comportamento [Ste89] e de tarefas naturais e tarefas artificiais [Azev93].

Hoje em dia, pesquisas na área de arquiteturas de computadores procuram desenvolver estruturas altamente paralelizadas a fim de otimizar os tempos envolvidos nos ciclos de busca e execução de instruções, procurando, de certa forma, superar algumas das limitações apresentadas pelos computadores digitais convencionais supra citados. Entre as arquiteturas mais avançadas pode-se citar as arquiteturas hiper-cúbicas, máquinas sistólicas, “data-flow”, “pipeline”, etc. Apesar do alto grau de paralelismo presente nestas arquiteturas, todas elas se baseiam no princípio da execução de instruções para a realização do processamento desejado (ainda, arquiteturas von Newmann), adotando uma abordagem algorítmica para a solução de problemas[Nasc94].

Uma alternativa que tem se mostrado viável às arquiteturas von Newmann, é a utilização de um grande número de simples unidades de processamento (PE) com um alto grau de interconexão. Este paradigma apresenta uma inspiração biológica muito forte pois as unidades de processamento procuram modelizar os neurônios biológicos e as interconexões entre eles, formando redes de neurônios. A idéia é de tentar imitar a estrutura do cérebro biológico, na esperança do surgimento de um comportamento inteligente emergente. Como é fundamental para este trabalho o entendimento de tais estruturas, nos próximos itens será visto uma pequena introdução sobre o assunto.

2.1.1 - Morfologia do Neurônio Biológico

A implementação de Redes Neurais Artificiais tem inspirações nos neurônios biológicos e nos sistemas nervosos. A célula nervosa ou neurônio foi descoberta por um anatomista italiano Camillo Golgi em 1875. Ele introduziu um método em que, aparentemente aleatório, somente uma pequena população de células numa região são tingidos em sua totalidade e num certo tempo. Através deste tingimento, Golgi mostra somente poucos neurônios, cada um com toda a sua ramificação. Seu contemporâneo, o neurologista espanhol Santiago Ramón y Cajal, desenvolveu a existência de uma criatividade extraordinária, aplicando um novo método em todo o sistema nervoso. De

acordo com seus resultados, primeiramente Cajal adotou a noção do sistema nervoso, postulando sobre a comunicação entre as células nervosas através das sinapses. A segunda maior contribuição foi que a interconexão entre neurônios não seria feita ao acaso, pois é altamente específica e estruturada.

O neurônio é a unidade fundamental dos sistemas nervosos, particularmente do cérebro biológico. Como qualquer célula biológica, o neurônio é delimitado por uma fina membrana celular que além de sua função biológica normal, possui determinadas propriedades que são essenciais para o funcionamento elétrico da célula nervosa. De um ponto de vista clássico, o neurônio é uma simples unidade de processamento que recebe e combina sinais de muitos outros neurônios através de canais de entrada filamentosos, os dendritos. (figura 2.1).




Figura 2.1 - Neurônio biológico

A função dos dendritos é receber informações ou impulsos nervosos de outros neurônios e conduzi-los ao corpo celular: o soma.

O soma possui uma forma piramidal ou cilíndrica, onde acontecem as funções necessárias à manutenção da vida dos neurônios, tais como síntese de enzimas e outras moléculas. A informação então é processada gerando, assim, novos impulsos, onde o axônio retransmitirá a outro neurônio, ou a um grupo de outros neurônios, com o qual mantém contato, geralmente, através de um de seus dendritos.

O neurônio possui geralmente um único axônio. Em alguns casos, estende-se por distâncias comparáveis as dimensões do organismo, podendo chegar a comprimentos macroscópios. [Kov96].

As conexões (ou junções) entre o axônio de um neurônio e o dendrito de outro neurônio é chamado de sinapse. Um simples neurônio pode ter cerca de 1000 a 10.000 sinapses.

Uma sinapse consiste num terminal pré-sináptico, por onde chega um estímulo proveniente de uma outra célula, e o terminal pós-sináptico, que é a do dendrito. Nesta região intersináptica, o estímulo nervoso que chega à sinapse é transferido à membrana dendrital através de substâncias conhecidas como **neurotransmissores**. O resultado desta transferência é uma alteração no potencial elétrico da membrana pós-sináptica. Dependendo da natureza dos neurotransmissores e pela natureza dos receptores químicos que os recebem no outro lado da sinapse, a conexão será excitatória ou inibitória.

Em uma sinapse inibitória, a transmissão sináptica provoca uma pequena hiperpolarização no potencial elétrico do neurônio afetado. Isto faz com que seja mais difícil para este neurônio se despolarizar e propagar seu próprio potencial de ação ao longo do seu axônio.

Ao contrário, em uma sinapse excitatória, a transmissão sináptica provoca uma pequena despolarização no neurônio afetado, rebaixando seu potencial elétrico em direção a um ponto mínimo crítico, onde ele repentinamente pode se despolarizar a ponto de iniciar a transmissão de seu próprio potencial de ação através do seu axônio [Rois96].

2.1.2 - Modelo Geral de Neurônio

O primeiro modelo de neurônio foi proposto por McCulloch e Pitts em 1943 [McC43]. Neste trabalho nós vamos considerar como modelo geral do neurônio aquele apresentado por J. Dayhoff [Day90] o qual é uma generalização do modelo de McCulloch e Pitts sendo constituído como mostra a Figura 2.2.




Figura 2.2 - Modelo de Neurônio [Day90]

No lado esquerdo estão as múltiplas entradas da unidade de processamento, cada uma chegando de outras unidades, e estão conectados em uma unidade mostrada no centro. Cada interconexão tem associada uma força de conexão, dado por w_1, w_2, \dots, w_n , que pode ser excitatória (positiva) ou inibitória (negativa), normalmente variando de -1 a 1. A unidade de processamento realiza a soma dos pesos das entradas e usa uma função $f(.)$, não linear, para computar a saída. O resultado calculado é, então, enviado as conexões de saída para as células mostradas a direita da figura.

Apesar de ter sido provado por Arbib [Arb87] a equivalência, do ponto de vista de computabilidade, entre redes neurais artificiais e computadores digitais que conhecemos, usando portas lógicas. Entretanto, como o caso de uma porta lógica, os neurônios, isoladamente, não são capazes de muito poder computacional. Daí a idéia de juntá-los em redes de neurônios de forma a aumentar o poder computacional e na esperança de um comportamento emergente.

As redes neurais são, então, compostas basicamente por vários neurônios. Alguns neurônios recebem excitações do exterior e são chamados neurônios de entrada e correspondem aos neurônios dos sentidos, nos sistemas biológicos. Outros têm suas respostas usadas para alterar, de alguma forma, o mundo exterior e são chamados neurônios de saída e correspondem aos moto-neurônios que são os neurônios biológicos que excitam os músculos. Os neurônios que não são nem entrada nem saída são conhecidos como neurônios internos. Estes neurônios internos à rede têm grande importância e são conhecidos na literatura como *hidden* [Bar96]. Uma delas é que Minsky e Papert [Mins69] provaram que redes com apenas uma camada adaptativa não são capazes de tratar funções não linearmente separáveis.

2.1.3 - Topologia de Redes Neurais Artificiais

As redes neurais artificiais podem ter seus neurônios interconectados de tal maneira que formam diferentes topologias. Os dois tipos mais importantes são as redes *feedforward* e as redes *feedback*. Nesta seção serão apresentadas as duas topologias.

2.1.3.1 - Redes Diretas (Feedforward)

As redes diretas (*feedforward*) são aquelas que podem ser representadas por um grafo sem ciclos. Os sinais de saída de uma rede nunca dependerão dos valores anteriores e seus sinais se propagam num único sentido e as saídas dependem somente dos sinais que estão chegando dos outros neurônios, não havendo portanto, laços neste sistema [Mar90]. Uma vez treinadas, estas redes produzem sempre o mesmo resultado de saída para a mesma entrada [Law92].

Freqüentemente é comum representar as redes diretas em camadas e, neste caso, são chamados de redes em camadas. Neurônios que recebem sinais de excitação são chamados de camada de entrada, ou primeira camada. Neurônios que têm sua saída como saída da rede pertencem a camada de saída ou última camada. Neurônios que não pertencem nem a camada de entrada nem a de saída, são neurônios internos à rede e pertencem a uma ou mais camadas internas (*hidden*).

Nestes tipos de rede, geralmente utilizam-se métodos de aprendizado. Um dos métodos de aprendizado mais usado, atualmente, é o algoritmo *backpropagation* que será discutido na seção 2.1.5.1.

Uma característica muito importante apresentada por este tipo de rede é que elas são capazes de aproximar, com maior ou menor precisão, dependendo do número de neurônios da rede, qualquer função não-linear [Law92][Bar96].

Uma outra característica desta rede é que, pela falta de *loops* de realimentação a rede é estática. No entanto, é possível a introdução de dinâmica, neste tipo de redes, seja através da utilização de uma linha de retardos na entrada da rede, seja através da utilização de neurônios dinâmicos. Nestes casos a equação representativa do sistema (da rede) seria uma equação diferencial, no caso contínuo, ou a uma equação de diferença finita, no caso discreto.

Em qualquer dos casos, todavia, estas redes apresentam uma dinâmica limitada não podendo representar todos os sistemas dinâmicos [Bar96].

2.1.3.1.1 - Redes com uma única camada (*single-layer*)

Os primeiros trabalhos a serem realizados com redes diretas, utilizavam redes com apenas uma camada de neurônios de entrada que se conectam com os neurônios da camada de saída. Tais redes foram desenvolvidas, paralelamente, por Rosenblat (os Perceptrons) [Rosen58] e por Widrow - Hoff (os ADALINEs e MADALINEs) [Wid62].

A grande limitação deste tipo de topologia é a impossibilidade, demonstrada por Minsky & Papert, de se resolver problemas classificados como não linearmente separáveis [Min69].

2.1.3.1.2 - Redes multi-camadas (*multilayer*)

As redes multi-camadas apresentam, além da camada de entrada e da camada de saída, uma ou mais camadas de neurônios internos (camada *hidden*). A função dos neurônios internos é extrair características dos neurônios da camada de entrada e, em seguida, transmiti-las para os neurônios da camada de saída. Deste modo, a rede é capaz de extrair estatísticas de mais alta ordem. A figura 2.3 mostra uma rede direta com três camadas.




Figura 2.3 - Rede *feedforward* com três camadas

2.1.3.2 - Redes com realimentação (*Feedback*)

Redes com realimentação (*feedback*) são aquelas que podem ser representadas por um grafo que contenha ao menos um ciclo (Figura 2.4). Neste tipo de rede, a saída

de um neurônio está sempre relacionada a algum valor prévio de saída da rede, existindo assim laços de realimentação entre um neurônio e outro.

Duas destas redes têm particular importância: as redes propostas por Hopfield [Hopf82] e as redes bidirecionais como a BAM (Memória Associativa Bidirecional) [Kosk88].




Figura 2.4 -Redes *feedback* (Com realimentação)

Uma outra rede, sob esta classificação, de muito importância para o nosso trabalho é a rede IAC (*Interactive Activation and Competition*) que será discutida com mais detalhes na seção 2.2.

2.1.4- Aprendizado em Redes Neurais

Uma rede neural é configurada tal que a aplicação de um conjunto de entradas produz o conjunto desejado na saída. Existem vários métodos para determinar a força das conexões. Uma maneira é setar explicitamente as pesos, usando algum conhecimento “a priori”, como é o caso da rede IAC. Outra maneira é treinar a rede através de um algoritmo de aprendizagem. Este aprendizado pode ser supervisionado ou não-supervisionado.

2.1.4.1 - Aprendizado supervisionado

No método de aprendizado supervisionado, pares de entradas e saídas são apresentados à rede. Em seguida, com estas entradas, a rede produz uma resposta na saída. Compara-se, então, com o sinal da saída desejado. Caso a resposta real seja diferente da resposta desejada, a rede gera um sinal de erro, que será usado para calcular o ajuste dos pesos sinápticos. De forma a comparar os sinais desejados dos sinais reais gerados pela rede e tomar as decisões de mudanças de peso, faz-se necessário a presença de um professor. Daí a denominação de Aprendizado Supervisionado. O algoritmo *Backpropagation*, que é, hoje, o mais conhecido e usado algoritmo de aprendizado para redes neurais artificiais, é classificado como de aprendizado supervisionado.

2.1.4.2 - Aprendizado não supervisionado

Em uma rede não-supervisionada possui-se, somente, os dados relativos às entradas não se tendo informação de quais as saídas desejadas para cada uma daquelas entradas. Esta rede deve aprender por mecanismos de estímulo/reação, comparável à forma como as pessoas inicialmente aprendem uma linguagem: somente pela audição repetida de certas palavras em momentos particulares, as pessoas aprendem a fazer associações entre idéias e palavras [Law92]. Neste caso, não existe ninguém (um “professor”) para indicar se a associação feita está correta. A rede se encaminha interativamente num processo interno próprio de categorização da informação de entrada, também conhecido como *data clustering*, onde os dados de entrada são classificados em categorias nas saídas. [Ober89][Souc89]. Estas redes são ditas, também, auto-organizáveis e sua principal aplicação é em problemas de classificação. Um exemplo de rede deste tipo é o modelo de Kohonen [Koh88].

2.1.5 - Regras de Aprendizado

Essencialmente o aprender de redes neurais consiste em encontrar os valores de conexões sinápticas que resolvam um determinado problema. Em alguns casos, através

de um trabalho de “Engenharia de Conexões” (semelhante ao procedimento de “Engenharia de Conhecimento” em Sistemas Especialistas Simbólicos), os pesos das conexões são determinados “a priori” e armazenados na estrutura da rede, não havendo, portanto, uma fase de “real” aprendizado. Um exemplo típico deste caso é aquele dos modelos IAC (*Interactive Activation and Competition*). Em outros, quando não se conhece os valores das conexões, usam-se algoritmos de forma a determiná-los. A este algoritmo chama-se Algoritmo de Aprendizagem. A maioria dos algoritmos de aprendizado usados na atualidade derivam da Regra de Hebb que é discutida no próximo item.

2.1.5.1 - Regra de Hebb

Em 1949, Donald Hebb [Heb49] estabeleceu que quando um axônio de uma célula A está suficientemente próximo para excitar uma célula B e, repetitivamente ou persistentemente, ocorre o seu disparo, algum processo de crescimento ou uma mudança metabólica acontece em uma ou ambas células, tal que a eficiência de A, como uma das células disparadoras de B, é aumentada. Daí, a força sináptica, conhecida como peso W , entre a célula A e B, é modificada de acordo com um grau de atividade correlacionada entre entrada e saída [Kart96].

Matematicamente, a regra de Hebb é definida como:

$$\Delta W_{ij} = \eta \cdot Y_i \cdot X_j \quad (2.1)$$

para $j = 1, 2, \dots, n$

Onde:

ΔW_{ij} = ajuste de peso

η = taxa de aprendizado

Y_i = saída da rede

X_j = entrada da rede

Posteriormente Hebb enunciou o que poderia ser considerado o dual da lei enunciada anteriormente. Essa 2ª lei afirma que quando o neurônio tenta excitar o outro e não consegue, existe um mecanismo que enfraquece a conexão.

2.1.5.2 - Regra Delta

A regra delta é uma variação da regra de Hebb. Esta regra foi desenvolvida por Bernard Widrow e Ted Hoff [Wid62], por isso é conhecida também como regra de aprendizado de Widrow-Hoff ou como *Least Mean Square* (LMS), posto que minimiza o erro médio quadrático [Law92].

Este tipo de regra, baseia-se na idéia de ajustes contínuos do valor de pesos, tal que a diferença de erro (delta) entre o valor de saída desejada e o valor de saída real de um elemento de processamento (neurônio) é reduzido.

Matematicamente, a fórmula proposta torna-se:

$$\Delta W_{ij} = \eta \cdot (T_i - Y_i) \cdot \frac{d}{dx}(\text{net}_i) \cdot X_j \quad (2.2)$$

para $j = 1, 2, \dots, n$

Onde :

ΔW_{ij} = ajuste de peso

η = taxa de aprendizado

T_i = saída desejada

Y_i = saída real da rede

X_j = entrada da rede

$d(\text{net}_i)/dx$ = derivada da função ativação

2.1.5.3 - Regra Backpropagation

O algoritmo de aprendizado *backpropagation*, conhecida também como regra Delta Generalizada, foi descoberto, independentemente, por Werbos [Werb74] em 1974 e redescoberto por Parker [Park82] em 1982. Mas, somente com os trabalhos de Rumelhart et. al [Rum86] em 1986, que desenvolveu a forma pela qual a referida regra é conhecida atualmente, é que ela se popularizou.

Este tipo de algoritmo é amplamente utilizado como algoritmo de aprendizado em redes neurais multicamadas, com topologia *feedforward* de, no mínimo, duas camadas de pesos adaptativos.

A implementação do algoritmo *backpropagation* é dividida em duas partes. Na primeira fase, a entrada é apresentada e propagada através da rede para computar os

valores de saída para cada unidade de saída. Esta saída é comparada com o valor desejado, resultando em um sinal de erro, para cada unidade de saída. Na segunda fase, o erro é retropropagado para cada unidade na rede e mudanças de peso apropriadas são realizadas, nas diversas camadas adaptativas.

O peso de uma conexão é ajustado por um valor proporcional ao produto de um sinal erro δ da unidade i recebendo a entrada e a saída da unidade j enviando este sinal.

$$\Delta p \cdot w_{ij} = \gamma \cdot \delta_i^p \cdot o_j^p \quad (2.3)$$

Se a unidade é uma unidade de saída, o sinal erro é dado por:

$$\delta_i^p = (d_i^p - o_i^p) \cdot f'(i_i^p) \quad (2.4)$$

Tomando a função de ativação sigmoidal definida como

$$o_i^p = f(i_i^p) = \frac{1}{1 + e^{-i_i^p}} \quad (2.5)$$

o sinal erro para a unidade de saída é

$$\delta_i^p = (d_i^p - o_i^p) \cdot o_i^p \cdot (1 - o_i^p) \quad (2.6)$$

O sinal erro para as unidades hidden é determinado recursivamente em termos dos sinais erros das unidades para o qual ele está conectado.

Para a função de ativação sigmoidal

$$\delta_i^p = f'(i_i^p) \cdot \sum_{h=1}^{N_o} S_h^p w_{hi} \quad (2.7)$$

$$\delta_i^p = o_i^p (1 - o_i^p) \cdot \sum_{h=1}^{N_o} S_h^p w_{hi} \quad (2.8)$$

2.1.6 - Alguns Modelos de Redes Neurais

Existem vários modelos de redes neurais, cada um com suas características próprias, as quais, determinam quais os tipos de problemas mais adequados à uma solução através do referido modelo. Os mais conhecidos são: Perceptron, Adaline, MAdaline, Perceptrons multi-camadas (redes *feedforward*), Kohonen, IAC, Hopfield, ART, BAM e outros.

Estudos mais aprofundados de cada um destes modelos podem ser encontrados em [Zur92][Day90][Hay94][Rum86].

Neste trabalho concentra-se apenas na abordagem do modelo IAC (*Interactive Activation and Competition*) que será discutido no próximo item.

2.2 - Redes IAC

O modelo IAC (*Interactive Activation and Competition*) é uma arquitetura de Rede Conexionista apresentada originalmente por Rumelhart e McClelland no livro PDP - *Parallel Distributed and Processing* [Rum86] em 1986. Modelos desta natureza têm sido estudados, também, por Grossberg [Rum86]. e, posteriormente, por de Azevedo[Azev93].

A arquitetura IAC, apresenta uma topologia particular com características de Memórias Associativas, o que a torna bastante apropriada para a implementação de Sistemas Especialistas baseados no conceito de Memórias Associativas.

Memórias associativas são memórias "conteúdo endereçáveis", ou seja, os itens são recuperados por conteúdo, em contraposição aos modelos de memórias existentes nos computadores digitais atuais que poderiam ser denominados de "endereçáveis por endereços", onde os itens possuem um "endereço" que precisa ser fornecido para sua recuperação. Algumas propriedades apresentadas por memórias associativas que são, também, apresentadas pelo modelo IAC e que são desejáveis em Sistemas Especialistas são:

- recuperação das propriedades de um conceito a partir de seu nome;

- recuperação da descrição total de um conceito a partir de uma descrição parcial;
- recuperação do nome de um conceito a partir de suas propriedades;
- recuperação de generalizações apropriadas sobre o conjunto de conceitos.

2.2.1 - Modelo de Rumelhart e McClelland

A arquitetura original do modelo IAC é composta, basicamente, de unidades de processamento arranjadas em grupos (representando conceitos similares) que interagem entre si. Esta interação ocorre dentro dos grupos em que as unidades se encontram organizadas e divididas e, também, entre os diferentes grupos.

Existem conexões excitatórias entre unidades de diferentes grupos e conexões inibitórias entre unidades de mesmo grupo.

As conexões excitatórias, aqui atuando entre diferentes neurônios, de diferentes grupos, são bidirecionais. Ou seja, existindo uma conexão excitatória de uma unidade *i* para uma unidade *j*, existirá também uma conexão excitatória da unidade *j* para a unidade *i*. O fato destas conexões excitatórias serem bidirecionais, acabará criando condições para o surgimento de um processamento iterativo, pois o processamento em um determinado grupo influenciará e também será influenciado pelo processamento que ocorre em outros grupos da rede. As conexões inibitórias, geralmente são transferidas de cada unidade para todas as outras unidades de processamento, dentro de um mesmo grupo, ocasionando, assim, um tipo de processamento competitivo. Em cada grupo, todas as unidades são mutuamente inibitórias.

A Rede apresenta, ainda, dois tipos de grupos competitivos: grupos visíveis (unidades que recebem entradas do exterior) e grupos escondidos (unidades que não podem receber entradas do exterior), conforme visto na Figura 2.5. Portanto, deve-se especificar um padrão de entrada somente para os grupos visíveis.




Figura 2.5 - Modelo de Rumelhart e McClelland. O grupo de verde representa o grupo escondido e os demais representam os grupos visíveis.

Pode-se observar, ainda, que no modelo IAC de Rumelhart e McClelland, as entradas positivas da rede tenderão sempre a excitar as unidades, enquanto que as entradas negativas da rede tenderão sempre a inibi-las.

As unidades em uma rede IAC mudam suas ativações de acordo com uma função que considera tanto a ativação atual da unidade, como também a entrada da rede procedente de outras unidades ou oriunda de fora da rede para esta unidade.

Na maioria dos modelos de Redes Neurais, a entrada da rede, para uma unidade particular i , é considerada a mesma, ou seja, é simplesmente a soma das influências de todas as outras unidades de processamento da rede mais alguma entrada externa à rede. Esta influência criada por alguma outra unidade, considerada unidade j , é apenas o produto da saída da unidade pelo peso da conexão da unidade j para a unidade i .

Equacionando o que foi descrito acima, chegamos a seguinte relação característica da entrada de uma unidade i , considerando um modelo de uma rede IAC:

$$net_i = \sum_j w_{ij} output_j + extinput_i \quad (2.9)$$

A cada nova entrada computada às unidades, temos uma nova mudança nas ativações destas unidades. O resultado desta alteração é obtido através das seguintes equações de atualização das ativações.

Considerando o resultado do $net_i > zero$, então teremos:

$$\Delta a_i = (max - a_i) net_i - decay(a_i - rest) \quad (2.10)$$

por outro lado, para $net_i < 0$, ou $net_i = 0$ teremos:

$$\Delta a_i = (a_i - min) net_i - decay(a_i - rest) \quad (2.11)$$

Existem vários parâmetros no modelo IAC de Rumelhart e McClelland que podem ser controlados pelo usuário, como, por exemplo, os parâmetros de mínima e máxima ativação das unidades. Existem ainda outros parâmetros que são: nível de ativação de repouso, taxa de declínio, parâmetro que mostra a força das entradas externas e as escalas de parâmetros de força das entradas excitatórias e inibitórias para as unidades provenientes de outras unidades da rede. Estes parâmetros são representados como segue abaixo:

- **min** - ativação mínima;
- **max** - ativação máxima;
- **rest** - nível de ativação de repouso para o qual as ativações tendem a estabelecer-se na falta de uma entrada externa;
- **decay** - taxa de decaimento, o qual determina a força da tendência de retorno ao nível de ativação de repouso;
- **estr** - representa a força das entradas externas;
- **alpha** - gradua a força das entradas excitatórias sobre as unidades, provenientes de outras unidades da rede;
- **gamma** - gradua a força das entradas inibitórias sobre as unidades, provenientes de outras unidades da rede.

Tipicamente os parâmetros usados nas simulações de McClelland e Rumelhart são: $\max = 1$, $\min = 0.2$, $\text{rest} = -0.1$, $\text{decay} = 0.1$, $\text{estr} = 0.4$.

Os 5 (cinco) primeiros parâmetros podem ser representados através do gráfico da figura 2.6.




Figura 2.6 - Gráfico dos parâmetros

Pode-se dizer que alguns parâmetros citados acima têm significado biológico. Por exemplo, a curva de decaimento (*decay*) refere-se ao esquecimento dos seres humanos e o parâmetro *rest* significa que, geralmente, não se tem esquecimento total.

Como a rede IAC é também uma rede realimentada (com *feedback*), o tempo é discreto, pois o processamento é dividido em seqüência de passos, ou ciclos. Cada ciclo inicia com todas as unidades possuindo um valor de ativação, determinado no final do ciclo precedente, e os novos valores de ativação são considerados somente em um novo ciclo. Então, o processo de atualização de cada unidade é síncrono.

O princípio de operação é semelhante à rede de Hopfield, isto é, não existe uma fase de aprendizado e o usuário estabelece a topologia e o estado inicial da rede.

Um problema que pode ser observado no modelo de Rumelhart e McClelland está relacionado aos passos de ativação em cada ciclo, pois quando estes são grandes, a aproximação de tempo discreto pode gerar instabilidades no processamento.

Uma forma de eliminar este problema e ao mesmo tempo obter uma aproximação ao caso contínuo, é utilizar passos pequenos em cada ciclo.

2.2.2 - Modelo de Grossberg

A principal diferença do modelo de Grossberg com relação ao de Rumelhart e McClelland diz respeito a formulação das equações. Na formulação de Grossberg, as entradas excitatórias e inibitórias, para uma certa unidade, são tratadas separadamente, sendo que, a entrada excitatória (e) direciona a ativação da unidade para o valor máximo, enquanto que a entrada inibitória (i) a direciona de volta ao valor mínimo.

Para a taxa de declínio, o raciocínio é o mesmo seguido por Rumelhart e McClelland, onde este parâmetro tende a restaurar a ativação da unidade para seu nível restante.

Equacionando, temos que:

$$\Delta a = (max - a)e - (a - min)i - decay(a - rest) \quad (2.12)$$

A formulação de Grossberg apresenta a vantagem de permitir que uma equação simples manipule a evolução do processamento, ao invés de utilizar uma laço “se”, para determinar qual de um grupo de duas equações será utilizada no processamento.

Neste modelo observamos mais uma diferença com relação ao modelo de Rumelhart e McClelland, pois as entradas não são computadas como no modelo anterior, onde a entrada positiva sempre tenderia a excitar a unidade enquanto que a entrada negativa tenderia a inibi-la. Aqui o efeito de uma certa entrada pode ser excitatório quando a ativação de entrada é baixa e inibitório quando sua ativação for alta.

Neste aspecto, a regra para as entradas da rede seguida por Rumelhart e McClelland parece levar alguma vantagem sobre a de Grossberg, se considerarmos que na primeira, as influências excitatórias e inibitórias independem da ativação das unidades receptoras.

2.2.3 - Modelo de Azevedo

A arquitetura sugerida por de Azevedo foi inspirada no modelo IAC proposto por Rumelhart e McClelland, e também estudado por Grossberg.

No modelo de Azevedo, permitem-se conexões não somente entre grupos de unidades visíveis e escondidas mas também entre grupos de unidades visíveis, ou seja, o modelo de Azevedo permite a existência de relações diretas entre todos os grupos e, eventualmente, não se faz necessário o grupo escondido, como visto na Figura 2.7

Estas conexões são bidirecionais, criando condições para o surgimento de um processo iterativo, onde o processamento em cada grupo influenciará e será influenciado pelo processamento em outros grupos. Mais ainda, os pesos sinápticos estão compreendidos no intervalo de $[-1 \ 1]$ representando o grau “fuzzy” ou a força da relação entre os conceitos representados pelas unidades.

Isto implica em uma matriz simétrica com elementos nulos na diagonal principal. A escolha desta matriz é interessante porque, como mostrado por Cohen, se $w_{ij} = w_{ji}$ e $w_{ii} = 0$ os pontos de equilíbrio da rede neural são estáveis [Coh83].




Figura 2.7 - Modelo de Azevedo

Em seu primeiro modelo, de Azevedo considera a existência de dois tipos de unidades de processamento, ou seja, unidades visíveis, que estão habilitadas a receber entradas de fora da rede, e unidades escondidas, que não podem receber entradas externas da rede. Já em seu segundo modelo, são utilizadas apenas unidades visíveis.

de Azevedo, cria condições para que todos os grupos de unidades de processamento, sejam elas visíveis ou escondidas, possam estar diretamente conectados entre si. Outra vantagem no modelo de Azevedo, refere-se a utilização da lógica *fuzzy* nas conexões sinápticas.

Neste trabalho utilizamos o modelo de Azevedo sem a camada escondida, visto que, em seu trabalho [Azev93], de Azevedo mostra que esta camada não se faz necessária, pois os resultados obtidos tanto num modelo como em outro, não apresentam diferença qualitativa significativa.

CAPÍTULO 3: O Sistema Computacional

3.1 - Introdução

Rumelhart e McClelland implementaram o modelo IAC (*Interactive Activation and Competition*) no pacote de *software* PDP (*Parallel Distributed Processing*) implementado pelo grupo PDP, em 1986, liderado por Rumelhart [Rumelhart/86]. Recentemente foi lançada uma versão melhorada deste *software*, mas que apresenta o inconveniente de ter sido desenvolvida para plataforma UNIX. Ao que se saiba não existe uma versão para rodar sob Windows95.

Os objetivos principais para o desenvolvimento de um sistema computacional próprio, foram vários. Primeiro, o sistema deveria eliminar a maioria das limitações encontradas no pacote original do grupo PDP. Estas limitações referem-se, primeiramente, à quantidade de grupos e de neurônios, possíveis de serem implementados, limitado pelo "tamanho" da tela de vídeo. Segundo, o sistema original do grupo PDP, é, hoje, muito rudimentar no sentido de definição das topologias de redes, definição de parâmetros, interface com o usuário, roda sob DOS, etc. É óbvio que estas críticas são válidas hoje, em função dos novos avanços nos sistemas computacionais, tanto a nível de *hardware* como a nível de *software*, e não à época de sua disponibilização em 1986. Terceiro, faz-se necessário disponibilizar, junto com os modelos de Rumelhart e de Grossberg, para as redes IAC, o modelo de Azevedo. Mais, ainda, o *software* deve permitir que, em trabalhos futuros, módulos contendo outros modelos de redes conexionistas, sejam *feedforward* ou recursivas, possam ser acrescentados à estrutura existente e disponibilizados no menu principal.

Para implementar o sistema, um programa foi desenvolvido para plataforma IBM-PC compatível e escrito em Visual Basic 3.0 sob ambiente Windows de forma a disponibilizar uma boa interface usuário-máquina.

O sistema está dividido em três módulos principais que são: módulo da escolha do modelo de redes conexionistas, módulo da escolha das versões e módulo de traçar

gráficos. O primeiro módulo consiste na escolha de qual tipo ou modelo de redes conexionistas o usuário pretende trabalhar. O segundo módulo refere-se a escolha de uma das versões (Rumelhart, Grossberg ou de Azevedo). É neste módulo que a rede é implementada e executada. O terceiro e último módulo a ser descrito é o módulo de análise dos resultados através de gráficos dos transitórios de níveis de ativação dos neurônios. Estes módulos são discutidos a seguir.

3.1.1 - Módulo 1 - Escolha do Modelo de Redes Neurais

Uma vez inicializado o programa, visualiza-se a tela de apresentação (mostrada na figura 3.1).



Figura 3.1 - Tela de apresentação do sistema.

Em seguida parte-se para o Módulo 1, qual seja, o da Escolha do Modelo de Redes Conexionistas. É importante ressaltar que neste módulo apenas as redes IAC, objeto deste trabalho, foram implementadas. É considerada a possibilidade de futuras

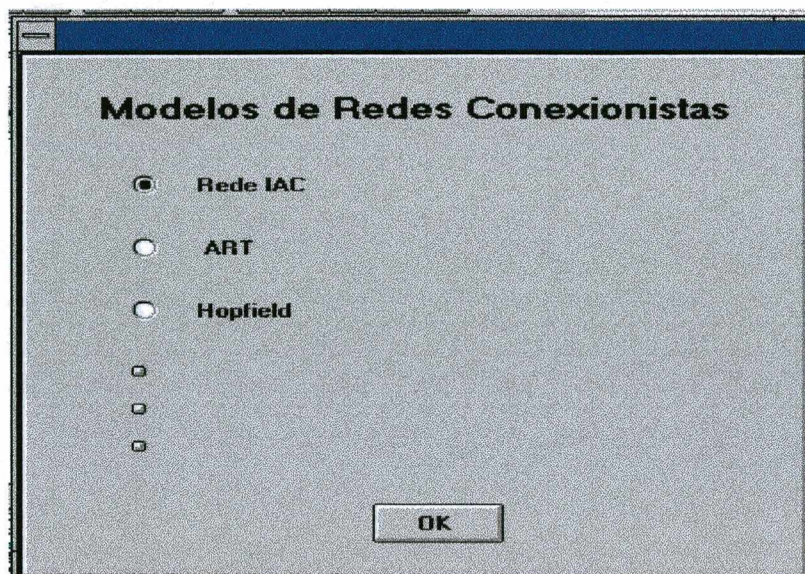


Figura 3.2 - Tela da escolha do modelo de redes conexionistas.

Após a escolha do modelo de redes (repetindo que, neste estudo, somente as redes IAC estão implementadas), passa-se ao Módulo 2.

3.1.2 - Módulo 2 - Escolha das Versões

A partir deste módulo tem-se, na parte superior, o menu do sistema contendo as seguintes funções: ARQUIVO, VERSÕES, PARÂMETROS, CICLO, JANELA e AJUDA.

No menu ARQUIVO, existe a possibilidade do usuário entrar com uma nova rede ou carregar um arquivo com extensão .IAC, que já tenha sido salvo anteriormente.

Se a escolha for uma nova rede, o usuário terá que entrar com o número de grupos, a quantidade de neurônios em cada grupo, dando, em seguida, um “nome” para cada neurônio, definindo, desta forma, a estrutura da nova rede, à qual deverá ser designado um nome também com a extensão .IAC.

Se a escolha for abrir um arquivo já existente, aparecerá na tela principal, após a seleção da rede desejada, a estrutura desta rede apresentando os vários grupos com seus respectivos neurônios sendo que, cada grupo será representado por uma janela menor conforme visto na figura 3.3. A matriz sináptica também é carregada.

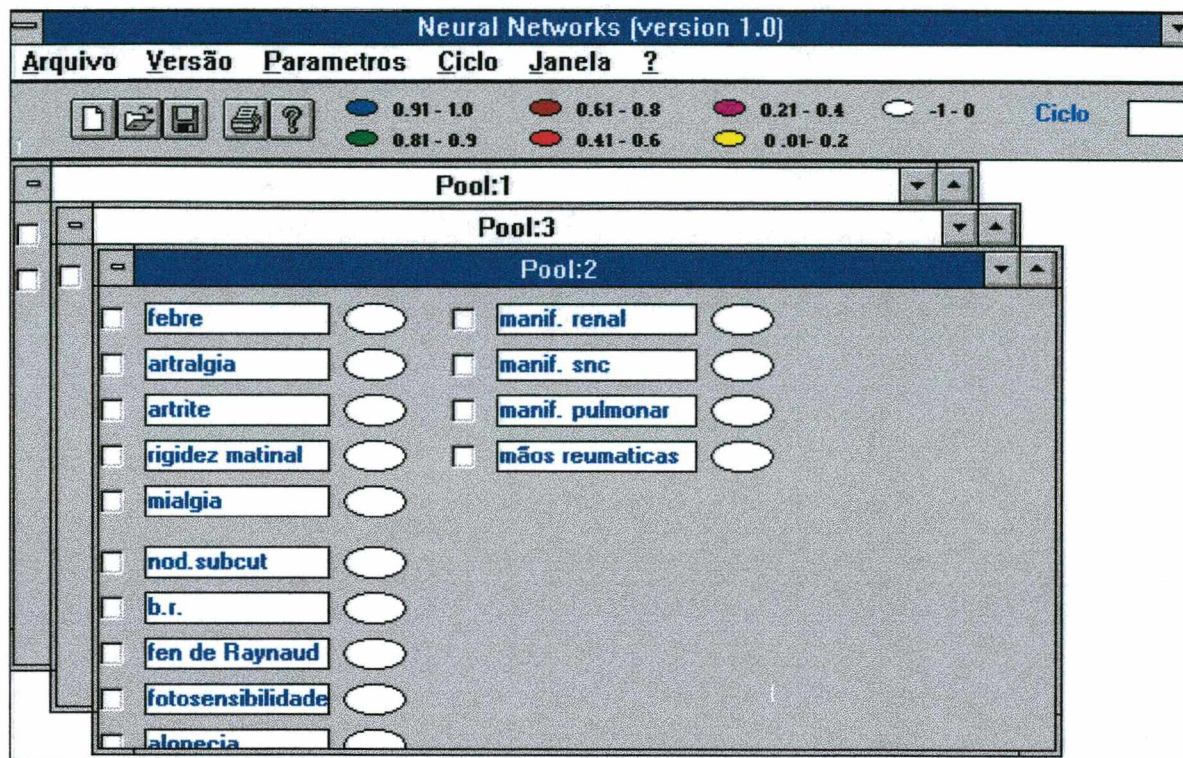


Figura 3.3 - Tela apresentando a estrutura de uma Rede IAC.

Como pode ser visto, o modelo IAC é composta de unidades de processamento arranjados em grupos. Cada tela menor, vista na figura 3.3, representa um grupo. A quantidade de grupos disponíveis neste software é de 7 grupos e mais um grupo referente à camada escondida (hidden), no caso dos modelos de Rumelhart e de Grossberg. Cada grupo contém uma certa quantidade de neurônios, podendo em cada grupo, existirem, no máximo 30 neurônios. Esta limitação se deve a memória disponível no computador que foi utilizado para desenvolvimento do software. No entanto, para computadores com mais memória disponível, essas limitações poderiam ser relaxadas.

No menu VERSÕES é possível escolher uma das três versões da rede IAC implementadas neste trabalho: Rumelhart, Grossberg, de Azevedo. Uma vez feita a seleção, aparecerá a camada escondida (hidden) para as versões de Rumelhart e Grossberg. Ou seja, o próprio programa cria uma camada escondida que é um espelho do grupo que possui maior número de neurônios. Mais ainda, as ligações entre neurônios pertencentes à um mesmo grupo já são definidas como -1.

No caso da versão de Azevedo, aparecerá somente uma mensagem informando que este modelo não possui a camada escondida.

O menu PARÂMETROS oferece a possibilidade da ~~mudança dos valores~~ dos parâmetros definidos na seção 2.2.1, ou seja, dos parâmetros: alpha, gamma, estr, min, max, decay e rest. Os valores iniciais destes parâmetros, tipicamente utilizados nas simulações de Rumelhart e McClelland, e assumidos neste sistema como "default" são: max = 1; min = -0.2; rest = -0.1 e estr = 0.4.

O menu CICLO serve para criar as ligações (ou conexões) entre os neurônios dos diferentes grupos, dependendo da versão escolhida. Ou seja, para as versões de Rumelhart e de Grossberg, faz-se as conexões que podem tomar dois valores {0, 1}. A escolha dos valores é feita em função da existência, ou não, de relação entre os dois neurônios (que representam, obviamente, dois conceitos).

Se a versão escolhida for a de Azevedo, as coisas são um pouco mais complicadas. Como já foi discutido no Capítulo 2, a versão de Azevedo admite valores de ligações entre neurônios no intervalo de [-1 1] representando o grau fuzzy ou a força da relação entre os conceitos representados pelas unidades. Desta forma, neste menu e neste modelo, os valores das conexões, tanto dentro de um mesmo grupo quanto entre diferentes grupos, têm de ser informadas ao sistema de forma a criar a matriz de forças sinápticas.

Depois da implementação da matriz sináptica, torna-se necessário definir o número de ciclos que se deseja realizar durante a execução do processamento, visto a topologia da rede ser *feedback*. Isto é feito dentro do menu CICLO escolhendo a seleção N.CICLO, conforme mostrado na figura 3.4.

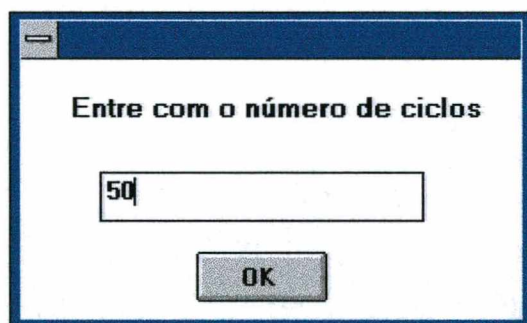


Figura 3.4 - Tela de entrada do número de ciclos.

Uma vez definido o número de ciclos, inicia-se o processo de execução mostrando na tela principal, o valor do ciclo. Ao terminar a execução, o valor da

ativação de cada neurônio é atualizado e mostrado na tela conforme visto abaixo (figura 3.5):

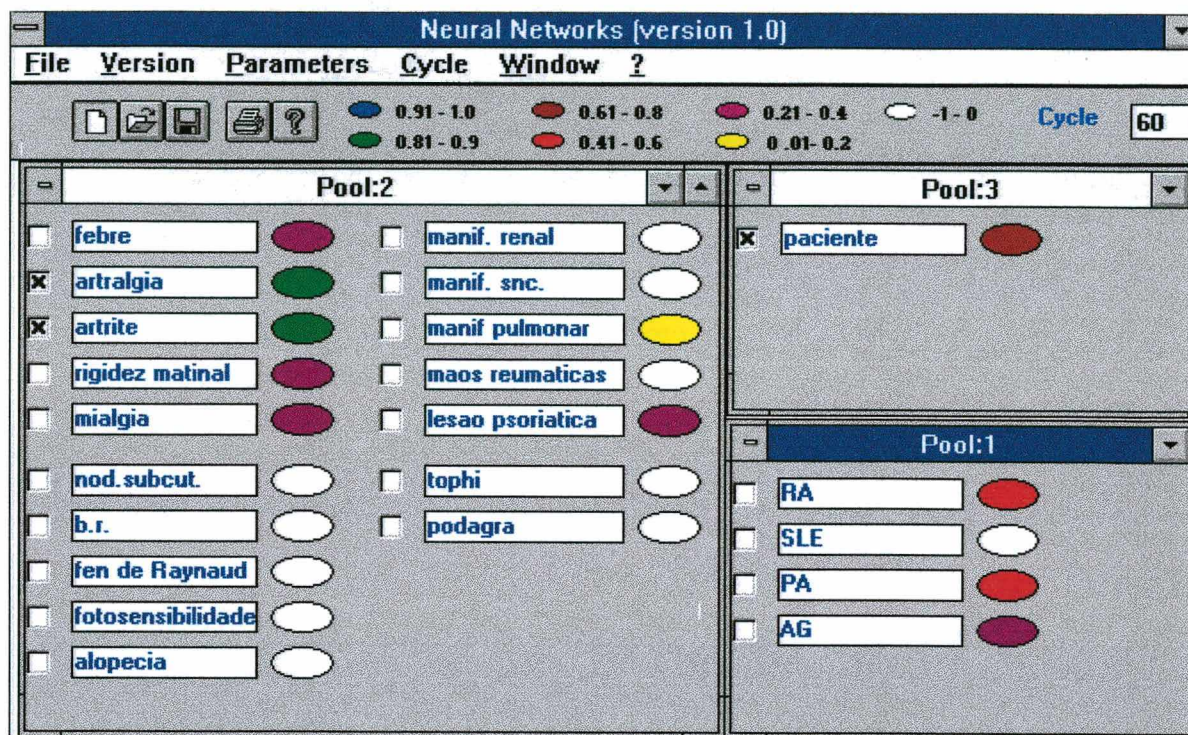


Figura 3.5 - Programa em execução.

Cada cor representa um intervalo de ativação, conforme segue e é, também, mostrado na parte superior da janela (Figura 3.5):

- valor de ativação entre 0.91 a 1 - cor azul;
- valor de ativação entre 0.81 a 0.90 - cor verde;
- valor de ativação entre 0.61 a 0.80 - cor marrom;
- valor de ativação entre 0.41 a 0.60 - cor vermelho;
- valor de ativação entre 0.21 a 0.40 - cor de rosa;
- valor de ativação entre 0.01 a 0.20 - cor amarela;
- valor de ativação -1 a 0 - cor branca.

O menu JANELA, permite ao usuário a escolha de como as janelas, representando os grupos, serão apresentadas. Podendo ser em cascata, lado a lado horizontalmente, ou usando o mouse, conforme desejado através do aumento ou diminuição de cada janela e seu posicionamento espacial no vídeo.

horizontalmente, ou usando o mouse, conforme desejado através do aumento ou diminuição de cada janela e seu posicionamento espacial no vídeo.

O menu AJUDA apresenta, como é de esperar, uma série de informações sobre a utilização de cada menu e opção, dentro do menu, de forma a ajudar o usuário iniciante.

O sistema desenvolvido, como pode ser visto, não é limitado em tamanho (número de grupos e de neurônios) como o *software* do pacote original PDP (*Parallel Distributed Processing*) proposto por Rumelhart e McClelland, mas sim pela quantidade de memória disponível. Para isso, cada grupo de neurônios é implementado em uma janela como visto na figura 3.5, cada janela podendo ser trazida para *foreground* quando desejado pela utilização do mouse. Navega-se portanto, através da representação dos grupos de neurônios.

O programa contém, também, ícones que servem para abrir um arquivo já existente, abrir um novo arquivo, salvar um arquivo e também para ajudar o usuário no funcionamento do programa.

3.1.3 - Módulo 3 - Análise dos Resultados (Gráficos)

O módulo 3 foi criado com a finalidade de traçar gráficos relativos aos transitórios dos níveis de ativação de determinados neurônios. Isto se deve à necessidade da observação dos transitórios de determinados neurônios de forma ao entendimento da dinâmica da rede, o que pode levar a um possível entendimento do porquê de uma determinada decisão, por parte da rede, dado um problema.

Neste módulo, basta o usuário determinar quais dos neurônios gostaria de traçar. Como, durante o ciclo de execução, é criada uma tabela com os valores de ativação de todos os neurônios em cada instante de tempo, um gráfico é gerado, conforme visto na figura 3.6.




Figura 3.6 - Gráficos dos neurônios pré-definidos.

Desta forma, no caso estudo implementado o qual consiste de um problema de Auxílio à Decisão Médica na Área de Reumatologia, se o usuário segue o transitório da rede neural, durante a fase de consulta, supõe-se que ele estará apto a entender as possíveis relações que possam existir entre as diferentes doenças, sintomas e, eventualmente, testes laboratoriais tornando-se, a "explicação" do raciocínio, clara.

3.2 - Validação do Sistema Computacional Proposto

De forma a validar o sistema proposto foram considerados os seguintes pontos. Primeiramente a base de conhecimentos aqui usada é a mesma utilizada por de Azevedo em [Azev93]. Segundo, o sistema desenvolvido por de Azevedo foi implementado com a ajuda de um especialista médico, no caso a Dra. Lícia Epprecht, M.D., do Dept. de Medicina Geral da UNIRIO, especialista em reumatologia. A validação do referido sistema foi, portanto, realizada pelo especialista em questão. Neste trabalho, na falta de um especialista médico, de forma a fazer alguma forma de validação, decidiu-se realizar uma série de simulações comparando os dois sistemas¹. Como os resultados qualitativos

¹ Faz-se necessário esclarecer que de Azevedo implementou dois sistemas: um com duas e outro com quatro patologias. Todos os dois validados pela Dra. Epprecht. Aqui, o sistema de Sigaki que foi validado foi aquele que considera duas patologias.

das simulações foram os mesmos pode-se considerar que "grosso modo" o sistema também está validado.

Para efeitos ilustrativos serão mostrados, a seguir, os mesmos três exemplos de diagnóstico apresentados por de Azevedo em [Azev93].

Exemplo 1 - O objetivo, neste exemplo, é mostrar a estrutura dos dados. A figura 3.7 mostra o resultado após 40 ciclos quando se excita o neurônio Pat do grupo de casos reais clínicos.

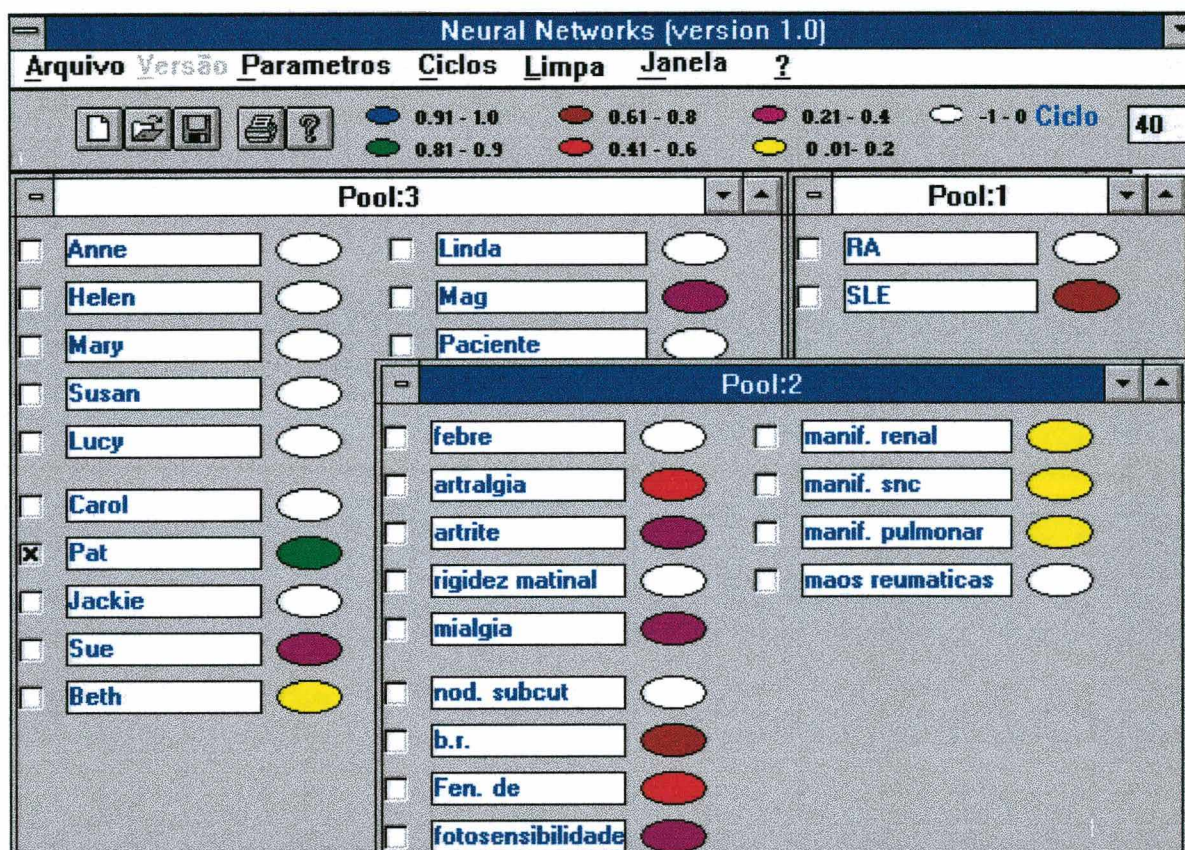


Figura 3.7 - Tela final de um caso particular da base de dados.

pode-se observar, através da figura 3.7 que:

- Na base de dados a paciente Pat está associada com artralgia, fenômeno de Raynaud, alopecia e erupção tipo borboleta (*Butterfly Rash*). Também é indicado na figura 3.7 os sintomas que não estão relacionadas com esta doença (Lúpus Eritematoso) que são: febre, rigidez matinal, nódulo subcutâneo e mãos reumáticas.

- No grupo (*pool*) de casos reais clínicos, outros casos foram excitados: Sue, Mag e Beth. Isto indica que estes casos citados acima, possuem sintomas similares, com diferentes graus de intensidade. Se é considerado a idéia do Case-Based Reasoning, pode-se dizer que estes três casos são os mais similares àquele apresentado à rede.

Exemplo 2 - Este exemplo mostra o caso de um paciente apresentando dois sintomas: artralgia e artrite, conforme apresentado na figura 3.8.

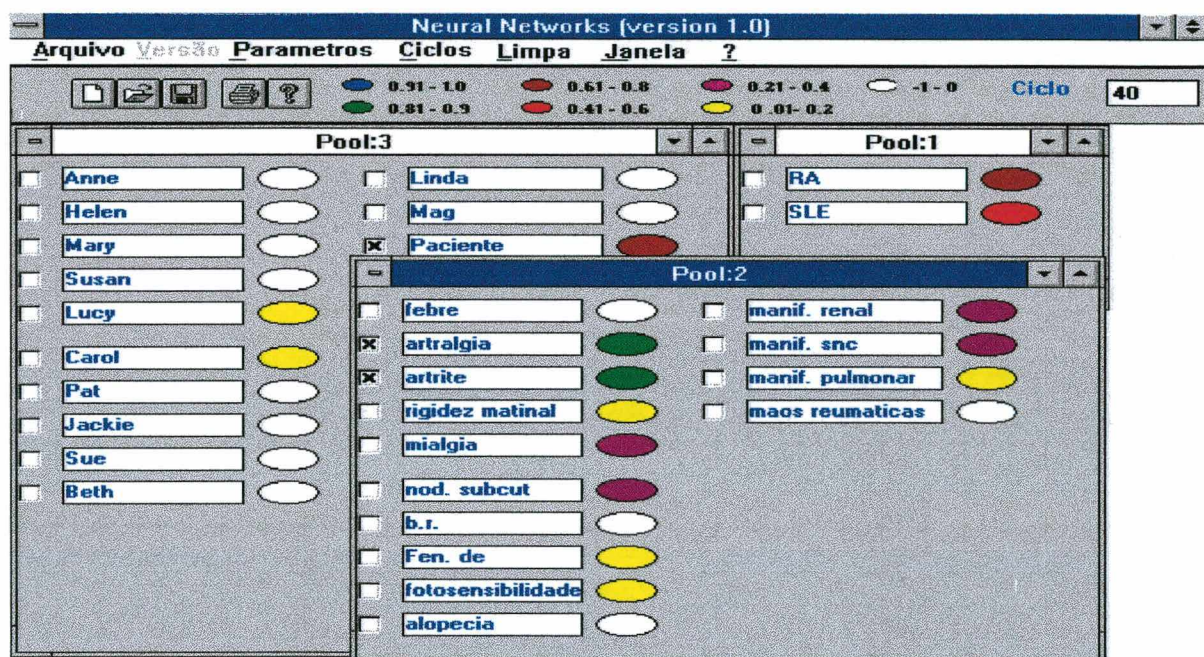


Figura 3.8 - Paciente inicialmente com dois sintomas: artralgia e artrite.

Como pode ser observado na figura 3.8, após 40 ciclos, estes dois sintomas não são suficientes para definir um diagnóstico.

Portanto, algumas informações suplementares são necessárias. Um novo sintoma, mãos reumáticas, é introduzido na rede. A figura 3.9 mostra o novo estado estável após a introdução de mais um sintoma e também após 40 ciclos. Este novo estado estável indica claramente o diagnóstico.

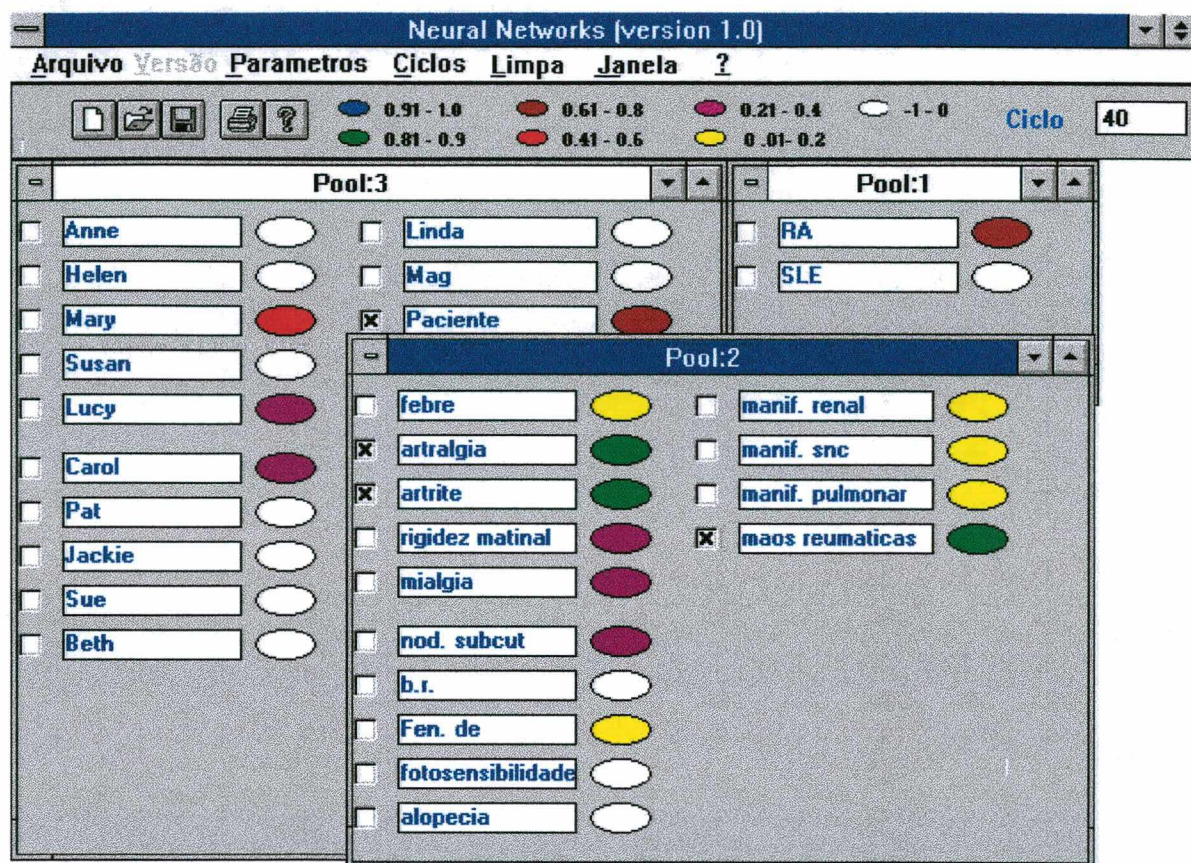


Figura 3.9 - Diagnóstico final do exemplo 2.

O gráfico da figura 3.10 mostra o transitório dos níveis de ativação das unidades representando as duas doenças. É possível observar que realmente a rede indica o diagnóstico.

Exemplo 3 - Este exemplo mostra o caso de um paciente com dois sintomas, mialgia e manifestação renal. O ponto de equilíbrio é atingido após 40 ciclos com as duas doenças sendo excitadas como mostrado na figura 3.11.




Figura 3.10 - Transitório dos níveis de ativação das duas doenças.

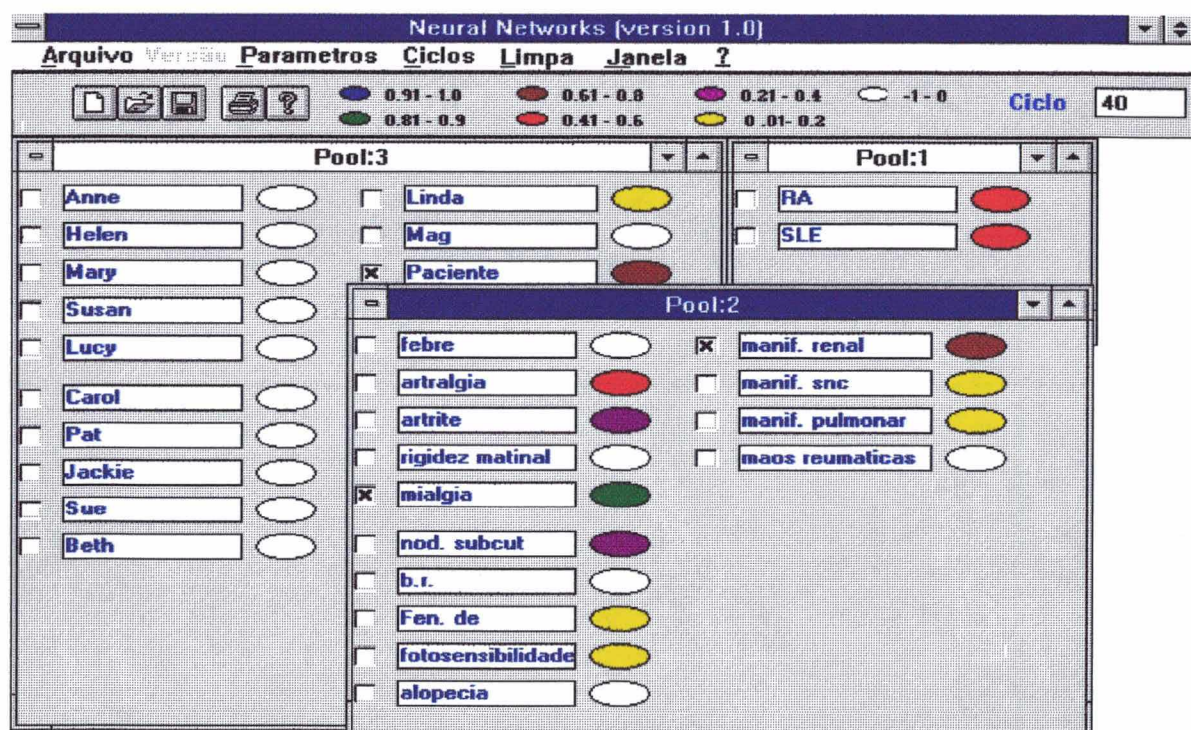


Figura 3.11 - Paciente inicialmente com dois sintomas: mialgia e manifestação renal.

Considerando o universo de discussão, somente cinco sintomas são capazes de fazer a distinção: exatamente aqueles de possuem baixo nível de ativação, ou seja, aqueles sintomas que estão representados com a cor branca (nível de ativação: 0 a -1). Estes sintomas são: febre, rigidez matinal, erupção em borboleta (Butterfly Rash), alopecia e mãos reumáticas. Um novo sintoma, então, é introduzido (rigidez matinal). A figura 3.12 mostra o novo estado estável após a introdução deste novo sintoma e após mais 40 ciclos. Este novo estado estável mostra claramente o diagnóstico.

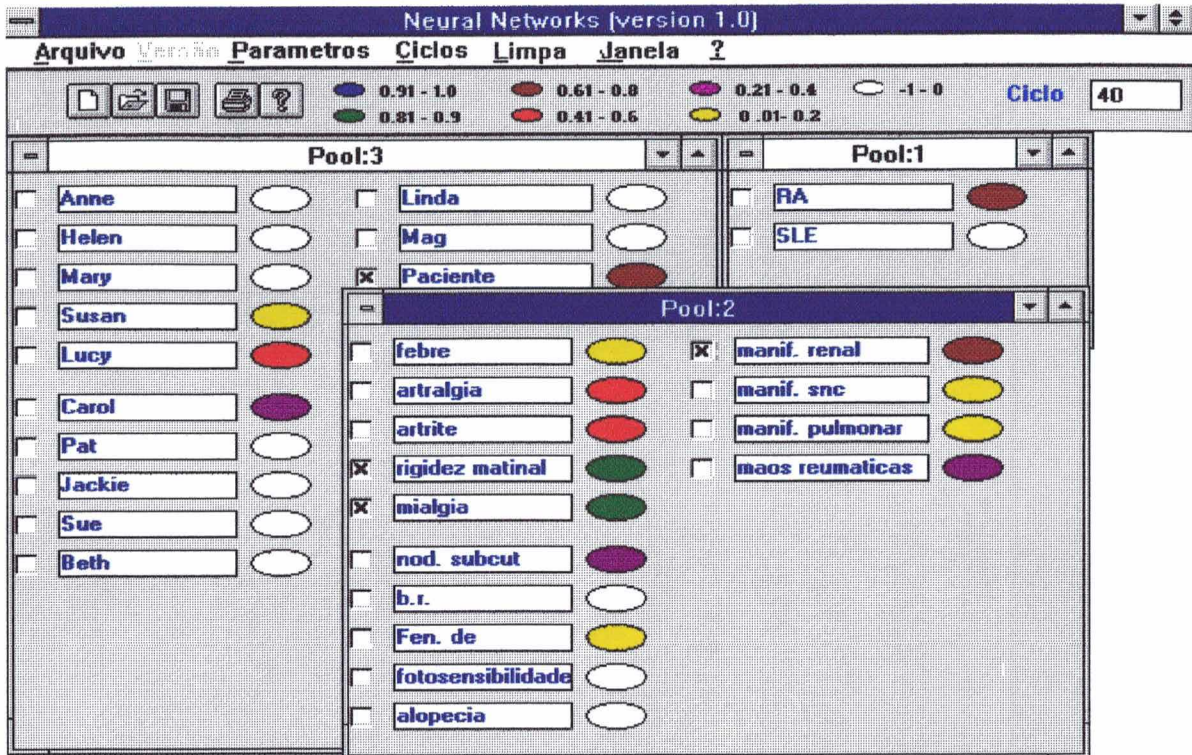


Figura 3.12 - Diagnóstico final do exemplo 3.

A figura 3.13 mostra o transitório dos valores de ativação das unidades que representam as duas doenças.




Figura 3.13 - Transiente dos níveis de ativação das duas doenças.

CAPÍTULO 4 - ESTUDO DO APRENDIZADO BASEADO EM CASOS

4.1 - Introdução

O modo básico de aprendizado, nestes tipos de redes, pode-se classificar como "Rote Learning". Ou seja, através de um trabalho de "Engenharia de Conexões" (semelhante ao procedimento de "Engenharia de Conhecimento" em Sistemas Especialistas Simbólicos) os pesos das conexões são determinados "a priori" e armazenados na estrutura da rede, não havendo, portanto, uma fase de "real" aprendizado.

É evidente que um algoritmo de aprendizado poderia ser implementado para estes tipos de rede. Tal algoritmo poderia se basear na lei de Hebb. Todavia, o desenvolvimento deste algoritmo não é o objetivo deste trabalho.

No entanto, qualquer que seja o caso, ou seja, regra de aprendizado ou engenharia de conexões, parece natural o uso de casos reais como fonte de conhecimento. Ou seja, não somente relações representadas por conhecimento estabelecido sobre relações sintomas / doenças e, eventualmente, exames laboratoriais, são utilizadas, mas também dados relacionados a casos clínicos reais. Desta forma a dinâmica da rede torna-se mais rica e pode ser conjecturado que um ponto de equilíbrio pode ser mais facilmente atingido por analogia com casos conhecidos, como é esperado em sistemas tipo *Case Based Reasoning* (CBR).

A idéia básica de CBR é adaptar soluções que foram usadas para resolver velhos problemas e usá-los para resolver novos problemas. CBR seguem diferentes processos, onde procuram na memória aqueles casos com problemas resolvidos similares ao do problema atual, e adapta solução ou soluções anteriores ao problema atual, levando em conta a distância (usando algum tipo de métrica) de forma a definir o grau de similaridade entre as situações atuais e anteriores.

Esta abordagem tem sido discutida como apresentando diversas vantagens teóricas com relação a mais tradicional abordagem de *Rule-Based Reasoning* dos Sistemas Especialistas, principalmente em problemas e domínios onde o processo de Engenharia de Conhecimento em obter regras é difícil ou intratável [Thr89].

Entre algumas das vantagens apontadas citam-se o entendimento e a modificação das bases de conhecimento (incluindo mecanismos de aprendizado), uma maior naturalidade e organização dos problemas dirigidos e um engrandecimento da funcionalidade da explanação.

4.2 - Estudo de Caso

O problema usado neste trabalho, para exemplificar e estudar a abordagem, constitui-se de um problema de Diagnóstico Diferencial em Reumatologia considerando 4 doenças, 17 sintomas e 24 casos reais conhecidos, diagnosticados por um especialista médico.

As doenças são: Artrite Reumatóide, Lúpus Eritematoso Sistêmico, Artrite Psoriática e Artrite de Gota. A seguir algumas informações sobre as patologias em questão são dadas.

Artrite Reumatóide

A Artrite Reumatóide (RA) é um processo inflamatório sistêmico crônico caracterizado por um padrão de morbididade nas articulações diartrodiais. Tendões, ligamentos, músculo e osso podem ser ameaçados pelo processo inflamatório.

A RA ocorre mundialmente em todas as raças e grupos étnicos. Pelos critérios diagnósticos habituais a doença é duas a três vezes mais prevalente entre as mulheres do que entre os homens, porém a aplicação de critérios mais rígidos como soropositividade (presença de fatores reumatóides) ou as indicações radiográficas de erosão tecidual mostram menor associação com o sexo. A incidência máxima no início fica entre a quarta e sexta décadas, porém a prevalência continua aumentando até a sétima década. As

determinações da prevalência global em vários estudos de várias populações oscilaram de 0,3 a 1,5%. Podemos tomar 1% como um número aproximado para a prevalência de RA na população adulta em geral.

Um diagnóstico de RA é compatível com uma ampla variedade de evoluções clínicas, indo desde uns poucos meses de desconforto até décadas de incapacidade acentuada. Talvez dois terços dos casos começam com sintomas que surgem paulatinamente durante um período de semanas ou meses. Mal-estar e fadiga caracterizam esse período, o mais das vezes em combinação com dor músculo-esquelética difusa. Com o progredir da doença, articulações específicas exibem dor, hipersensibilidade, tumefação e vermelhidão. O padrão de acometimento articular é tipicamente simétrico, envolvendo as mãos, os punhos, os cotovelos e os ombros.

Uma queixa freqüente é a rigidez após inatividade. Pode ocorrer pela manhã após levantar-se ou após ficar muito tempo sentado. É descrita por alguns como um processo de "congelamento" e parece estar associada com edema dentro dos tecidos inflamados. Esse sintoma é tão característico que a duração da rigidez matinal tem sido considerada como um guia para a gravidade do processo inflamatório. Na maioria dos estudos clínicos sobre RA, existem muitos dados quantitativos através dos quais é possível acompanhar a atividade da doença. Com o evoluir do processo, o paciente pode ter dificuldade progressiva com a dor e a rigidez. Isso limita a capacidade de movimentar-se livremente, de subir escadas, abrir portas, destampar latas ou realizar pequenos movimentos delicados, tais como costurar. O paciente pode desenvolver uma depressão psicológica associada e perda ponderal e, as vezes, pode ocorrer uma febrícula em associação com as manifestações sistêmicas da doença.

As considerações diferenciais no diagnóstico da RA são numerosas. Apesar de só raramente haver confusão na RA clássica, o diagnóstico pode ser mais difícil nos pacientes com poliartrite aguda em fase inicial ou naqueles com acometimento de apenas umas poucas articulações. Convém considerar Osteoartrite, Gota, Condromatose, Lúpus Eritematoso Sistêmico e Esclerose Sistêmica Progressiva como as doenças mais comuns que poderiam ser confundidas com RA. Além disso, inúmeras doenças

sistêmicas, incluindo Sarcoidose, Doença Intestinal Inflamatória, Doença de Whipple, Amiloidose, Infecção Crônica e Malignidades, podem manifestar-se, todas, por síndromes artríticas que simulam RA. Portanto, é indicada uma avaliação clínica completa em todos os pacientes com manifestações articulares. Deve-se avaliar o paciente para doenças sistêmicas gerais e também para causas curáveis, tais como infecções bacterianas. A análise minuciosa do líquido sinovial é fundamental na diferenciação entre Artrite Reumatóide e Gota Crônica. A avaliação crítica dos derrames articulares inflamatórios é útil, não apenas para o diagnóstico, mas também como guia para as respostas terapêuticas.

Lúpus Eritematoso Sistêmico

Lúpus Eritematoso Sistêmico (SLE) é uma doença de etiologia desconhecida, caracterizada por inflamação em muitos sistemas orgânicos diferentes e associada com produção de anticorpos reativos com antígenos nucleares, citoplasmáticos e da membrana celular. Cada paciente pode ter algum, porém não necessariamente todos, os seguintes elementos: fadiga, anemia, febre, erupções, sensibilidade ao sol, alopecia, artrite, pericardite, pleuris, vasculite, nefrite e alterações do sistema nervoso central. A evolução costuma ser imprevisível, com períodos variáveis de exacerbações e remissões. Não existe uma única anormalidade clínica capaz de estabelecer de maneira definitiva o diagnóstico, nem existe um teste único para o distúrbio. Como resultado, critérios foram elaborados e modificados na tentativa de incluir pacientes com SLE e excluir pacientes com outros distúrbios. Apesar desses critérios terem sido elaborados com finalidades epidemiológicas e de pesquisa, são igualmente úteis para o diagnóstico. Não obstante, é possível satisfazer estes critérios e não ter SLE, sendo igualmente possível não satisfazer o critério e ainda ter SLE. Assim sendo, uma mocinha adolescente com uma erupção tipo "borboleta" da face, pleuris e níveis altos de anticorpos séricos reativos com ADN nativo, sofre incontestavelmente de SLE mesmo quando ainda não manifestou quaisquer outros critérios. A doença deriva seu nome (*lupus* = lobo) da erupção facial, que se assemelha ao eritema malar de um lobo.

Apesar do SLE poder ocorrer em qualquer idade (já foi diagnosticado por ocasião do nascimento, assim como em indivíduos na décima década da vida), mais de 60% dos pacientes experimentam o início da doença entre os 13 e os 40 anos de idade. Entre as crianças, o SLE é três vezes mais comum em meninas do que em meninos. Dos pacientes na segunda, terceira e quarta décadas, 90 a 95% são mulheres. Daí por diante, a predominância feminina cai novamente para aquela observada antes da puberdade.

O SLE pode ser suspeitado em qualquer pessoa com patologia de múltiplos sistemas, incluindo dor articular. O Lupus Eritematoso pode ser suspeitado quando qualquer um dos critérios (erupção malar, erupção discóide, fotossensibilidade, úlceras orais, artrite, serosite, distúrbio renal, distúrbio neurológico, distúrbio hematológico, distúrbio imunológico e anticorpo antinuclear) está presente e não encontra explicação. O distúrbio deve ser aventado quando qualquer um dos seguintes estiverem presentes: febre inexplicável, púrpura, esplenomegalia, adenopatia, pneumonite, miocardite, ou meningite asséptica. A presença de um único sintoma, tipo serosite, juntamente com anticorpos para ADN nativo em uma mulher jovem, é muito sugestiva de SLE.

Com demasiada frequência as crianças são diagnosticadas erroneamente como tendo Febre Reumática ou Artrite Reumatóide Juvenil. Nos adultos, é feito mais comumente um diagnóstico errôneo de Artrite Reumatóide. Outros diagnósticos aplicados com certa frequência aos pacientes com SLE incluem doença de Raynaud, anemia hemolítica, trombocitopenia idiopática, púrpura trombocitopênica trombótica, psicose, vasculite, esclerose sistêmica progressiva, linfoma, neutropenia auto-imune, sífilis secundária, reação medicamentosa, porfilia, esclerose múltipla, miastenia grave, polimiosite, distúrbios de personalidade e distúrbio convulsivo.

Artrite Psoriática

É uma artrite inflamatória, soronegativa, ocorrendo em pacientes com psoríase. Não existe valor exato de incidência de Artrite Psoriática na população. Mas, aproximadamente 7% dos pacientes que possuem psoríase, desenvolve esta doença.

Apresenta-se, usualmente, na forma de uma Poliartrite crônica muito similar ao da doença Artrite Reumatóide.

Artrite de Gota

A Gota representa um grupo de doenças genéticas e desordens metabólica adquirida ordinariamente identificável por hiperuricemia. Quando clinicamente manifestada, a Gota apresenta-se como uma artrite inflamatória aguda, com depósito de sódio como tophi, ácido úrico nephrolithiasis, ou falha renal. Estas manifestações podem ocorrer em quaisquer combinações.

Na fase inicial, estas quatro doenças tem similar sintomatologia, alguns sintomas exclusivos de uma doença sendo frequentemente ausente (embora vários destes sintomas aparecem geralmente mais tarde). Isto faz um correto e difícil diagnóstico durante esta fase se baseado exclusivamente em dados clínicos e testes complementares são requeridos.

Para as 4 doenças acima citadas, existem vários sintomas associados mas, aqui, foram considerados apenas os seguintes 17 sintomas:

- Febre
- Artralgia
- Artrite
- Rigidez Matinal
- Mialgia
- Nódulo Subcutâneo
- Butterfly Rash (Erupção tipo Borboleta)
- Fenômeno de Raynaud
- Fotosensibilidade
- Alopecia
- Manifestação Renal
- Manifestação no Sistema Nervoso Central

- Manifestação Pulmonar
- Mãos Reumáticas
- Lesão Psoriática
- Tophi
- Podagra

Um conjunto de 24 casos reais clínicos foram considerados, sendo 6 diagnosticados como RA, 6 como SLE, 6 como PA e 6 como AG.

4.3 - Metodologia

Para a implementação do Sistema Especialista, utilizou-se o Sistema Computacional supra citado e, como base de dados, a matriz de pesos sinápticos, obtida do trabalho de Azevedo [Azev93]. O diagrama de blocos visto na figura 4.1, refere-se ao sistema geral proposto neste trabalho.

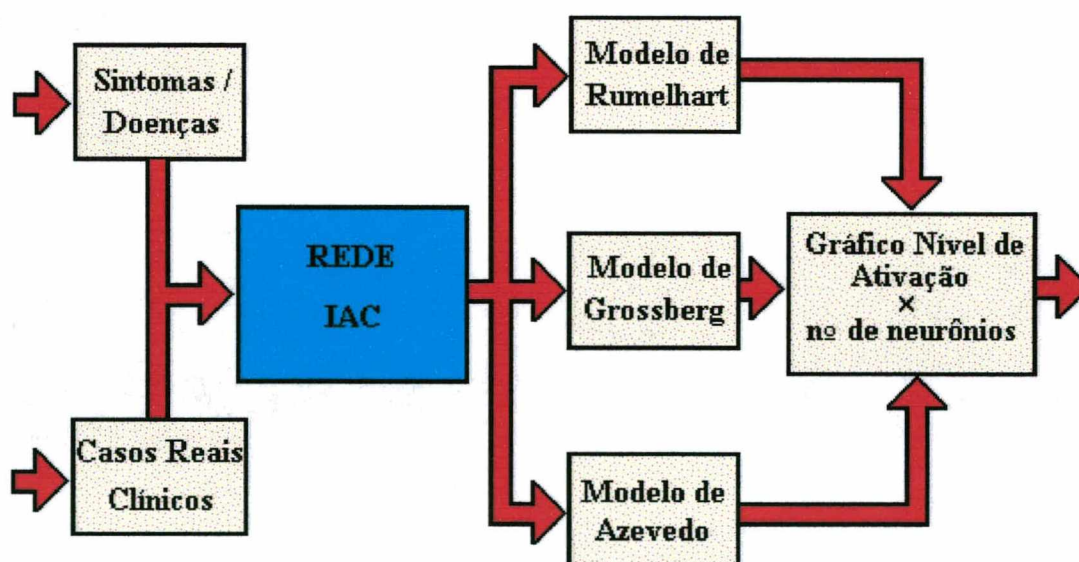


Figura 4.1 - Diagrama de blocos do programa

Dois SE foram implementados. Um considerando um estudo de caso reduzido e que, aqui, será denominado de Sistema "Reduzido". E um segundo considerando o estudo de caso completo e que, aqui, será denominado de Sistema "Completo".

No SE "reduzido" considerou-se apenas as duas primeiras doenças, Artrite Reumatóide e Lupus Eritematoso Sistêmico, e os quatorze primeiros sintomas, quais sejam: febre, artralgia, artrite, rigidez matinal, mialgia, nódulo subcutâneo, erupção tipo "borboleta" (*butterfly rash*), fenômeno de Raynaud, fotosensibilidade, alopecia, manifestação renal, manifestação no sistema nervoso central, manifestação pulmonar e mãos reumáticas. O conjunto de casos reais foi constituído por 12 casos, 6 para cada doença.

O SE "reduzido", foi implementado com dois objetivos. Primeiro, testar o sistema computacional desenvolvido. Segundo para poder fazer a validação do SE usando como comparação aquele de Azevedo [Azev93]. Explica-se: de Azevedo e Barreto implementaram, quatro sistemas. Mas desses quatro apenas dois nos interessam. O primeiro deles é idêntico ao aqui denominado SE "reduzido". No entanto, o segundo considerava um quarto grupo de neurônios constituído por Exames Laboratoriais. e, o SE "completo", aqui implementado, não considera esses exames laboratoriais. Consequentemente o SE "completo" não poderia ser comparado com àquele "completo" de Azevedo.

Um outro ponto a ser considerado é que tanto o SE "reduzido" quanto o SE "completo", aqui implementados, utilizaram-se apenas do modelo IAC de Azevedo. Não existem, portanto, implementações considerando os modelos de Rumelhart e de Grossberg. Tal fato deve-se a quase impossibilidade de resolver tal tipo de problema com estes dois últimos modelos. Explica-se: primeiro, nestes dois modelos as relações (força de conexão) entre os neurônios podem tomar apenas três valores, quais sejam $\{-1, 0, 1\}$, implicando na impossibilidade de tratar a incerteza e a imprecisão inerentes a este tipo de problema. Segundo, nos modelos de Rumelhart e de Grossberg, cada grupo (ou *pool*) de neurônios sofre um processo de competição "total" resultando que, em geral, apenas um neurônio sairá vencedor (com ativação fortemente positiva) por grupo. É claro que, em

alguns casos, será possível haver mais de um neurônio vencedor, por grupo (veja o exemplo *Jets and Sharks* em Rumelhart [Rum86]). Mas a força das conexões inibitórias, com valores de -1, dentro de um mesmo grupo, não é a melhor solução para quando se deseja fortemente a possibilidade de vários neurônios vencedores, por grupo. Ora, no caso de diagnóstico médico, vários sintomas estão associados à uma doença. Mais ainda, o grupo de casos reais conhecidos pode apresentar vários casos similares (com um grau de similaridade maior ou menor o que implica em uma distância menor ou maior) àquele sob estudo. E, para completar, apesar de improvável, é possível que um mesmo paciente apresente mais de uma doença, o que implicaria, novamente, em mais de um neurônio vencedor no respectivo grupo ou *pool*.

Da mesma forma que nos SE's de Azevedo, neste trabalho foram implementados três grupos, quais sejam: de doenças, de sintomas e de pacientes. Cada um destes grupos reúne os objetos da classe correspondente.

A metodologia do trabalho consiste, então, em primeiro validar os SE's. Este ponto foi discutido na Seção 3.2 e, para tal, foi utilizado o sistema "reduzido". Considerando que o desempenho do sistema "reduzido" apresentou-se qualitativamente semelhante aquele de Azevedo, pode-se conjecturar que o sistema "completo" foi, de certa forma, validado considerando-se que ele usa a mesma matriz de conexões que o correspondente de Azevedo à exceção do grupo (*pool*) de exames laboratoriais que, aqui, não foi considerado.

Para o estudo do desempenho da rede, na presença dos casos reais clínicos, e que é o objetivo principal deste trabalho, primeiramente a matriz sináptica da rede é construída considerando-se apenas as relações sintomas/doenças conforme visto na figura 4.1. Sua resposta é, então, observada para um conjunto teste cujas saídas reais são conhecidas. A resposta do sistema é observado não só do ponto de vista qualitativo, como também através do gráfico dos níveis de ativação dos neurônios correspondentes às doenças. A seguir, casos clínicos, um para cada doença, são introduzidos na matriz sináptica e, de novo, o sistema é avaliado para o conjunto teste. Este procedimento é, então, repetido, sempre acompanhado de uma avaliação do desempenho da rede.

O referido estudo de desempenho da rede na presença de casos foi realizado para os dois sistemas implementados: o "reduzido" e o "completo". Os resultados destas séries de simulações estão apresentados no próximo capítulo.

CAPÍTULO 5 - SIMULAÇÕES

5.1 - Introdução

Neste capítulo são apresentados os resultados das simulações. Duas séries de simulações são apresentadas: uma para o sistema "reduzido" e outra para o sistema "completo". Um número de simulações foi realizado dentro de cada uma destas séries. No entanto, por questões de espaço, serão apresentadas, aqui, apenas alguns exemplos com o intuito de ilustrar a abordagem.

5.2 - Simulações - Sistema "Reduzido"

Esta primeira série de simulações é realizada com o sistema "reduzido". Portanto somente 2 doenças (RA - Artrite Reumatóide e SLE - Lupus Eritematoso), 14 sintomas (febre, artralgia, artrite, rigidez matinal, mialgia, nódulo subcutâneo, erupção tipo borboleta, fenômeno de Raynaud, fotosensibilidade, alopecia, manifestação renal, manifestação no sistema nervoso central, manifestação pulmonar e mãos reumáticas) e 12 casos reais clínicos, 6 para cada doença são considerados.

Para implementar a versão de Azevedo, utilizou-se de 3 grupos sendo um para as doenças, um para sintomas e um para os casos clínicos diagnosticados.

O grupo de doenças contém apenas dois neurônios, sendo um neurônio representando Artrite Reumatóide e outro Lúpus Eritematoso. As conexões entre estes neurônios são inibitórias, mas não totalmente, posto que um paciente pode ter as duas doenças ao mesmo tempo, mesmo que isto seja improvável. A matriz que representa esta conexão é mostrada abaixo:

$$D/D = \begin{vmatrix} 0 & -0,9 \\ -0,9 & 0 \end{vmatrix}$$

O grupo de sintomas é constituído de 14 neurônios, cada um correspondendo a um dos 14 sintomas. A matriz que representa os sintomas/sintomas (S/S), é uma matriz nula 14x14, representando ignorância total sobre as relações entre sintomas.

O grupo que representa os casos reais clínicos diagnosticados, são constituídos de 13 neurônios que são: Paciente, Anne, Helen, Mary, Susan, Lucy, Carol, Pat, Jackie, Sue, Beth, Linda e Mag. A conexão entre eles é totalmente inibitória, significando que cada caso está isolado de outro caso, levando assim a competição entre os neurônios pertencentes a este grupo de casos clínicos. De fato, esta idéia é similar àquela utilizada na abordagem de CBR (*Case Based Reasoning*), que faz uso de casos anteriores para interpretar ou resolver novos casos e construir uma nova solução. A matriz de casos/casos é representada da seguinte forma:

$$C/C = \begin{vmatrix} 0 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & 0 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & 0 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & 0 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & 0 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & 0 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & 0 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & 0 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & 0 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & 0 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & 0 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & 0 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & 0 \end{vmatrix}$$

Existem, ainda, as conexões entre os diferentes grupos. Como já explicado, as forças destas conexões são fruto de um trabalho de Engenharia de Conexões similar àquele da Engenharia de Conhecimento. Estas conexões são, neste modelo, representadas, também, utilizando valores fuzzy de forma a tratar a imprecisão e a incerteza..

As conexões entre as doenças e os sintomas são dadas por:

$$D/S = \begin{vmatrix} 0.4 & 1 & 0.9 & 0.7 & 0.6 & 0.8 & -1 & 0.2 & 0 & -0.9 & 0.3 & 0.2 & 0.2 & 0.6 \\ -0.6 & 0.9 & 0.6 & -0.9 & 0.6 & 0 & 0.8 & 0.5 & 0.6 & 0.8 & 0.4 & 0.4 & 0.2 & -0.9 \end{vmatrix}$$

Entre os grupos de doenças e casos, os valores das conexões recebem apenas valores 1 e -1, ou seja, cada paciente tem Artrite Reumatóide ou Lúpus Eritematoso. Nenhum caso real diagnosticado pelo médico especialista apresentava o paciente como portador das duas patologias. O que seria, aliás, bastante interessante do ponto de vista de analisar o comportamento do sistema nesta situação. A matriz é dada por:

$$D/C = \begin{vmatrix} 1 & 1 & 1 & 1 & 1 & 1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & 1 & 1 & 1 & 1 & 1 & 1 \end{vmatrix}$$

Finalmente, as conexões entre sintomas e casos são dadas pela seguinte matriz:

$$S/C = \begin{vmatrix} 0 & 0.5 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0.5 & 0 & 0.5 & 0.5 & 0.5 & 0.5 & 0.5 & 0 & 0.5 & 0.5 & 0.5 & 0.9 \\ 0 & 0.9 & 0.5 & 0 & 0.5 & 0.5 & 0 & 0.5 & 0.5 & 0.5 & 0.5 & 0 \\ 0 & 0 & 0 & 0 & 0.5 & 0.5 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.5 & 0 & 0.5 & 0 & 0 & 0.5 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.9 & 0 & 0 & 0.9 & 0 & 0 & 0 & 0.5 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.9 & 0 & 0.9 & 0 & 0 & 0.9 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0.5 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.5 & 0.9 & 0 & 0.9 & 0 & 0 \\ 0 & 0.5 & 0 & 0 & 0.5 & 0 & 0 & 0 & 0 & 0 & 0.5 & 0 \\ 0 & 0 & 0 & 0 & 0.5 & 0 & 0 & 0 & 0 & 0 & 0.5 & 0 \\ 0 & 0 & 0 & 0.9 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.9 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{vmatrix}$$

Exemplo 1

Neste exemplo, foi considerado um paciente apresentando os sintomas artralgia, artrite e mãos reumáticas, conforme visto na figura 5.1. Observa-se, também, que não existem casos reais conhecidos neste estágio da simulação.

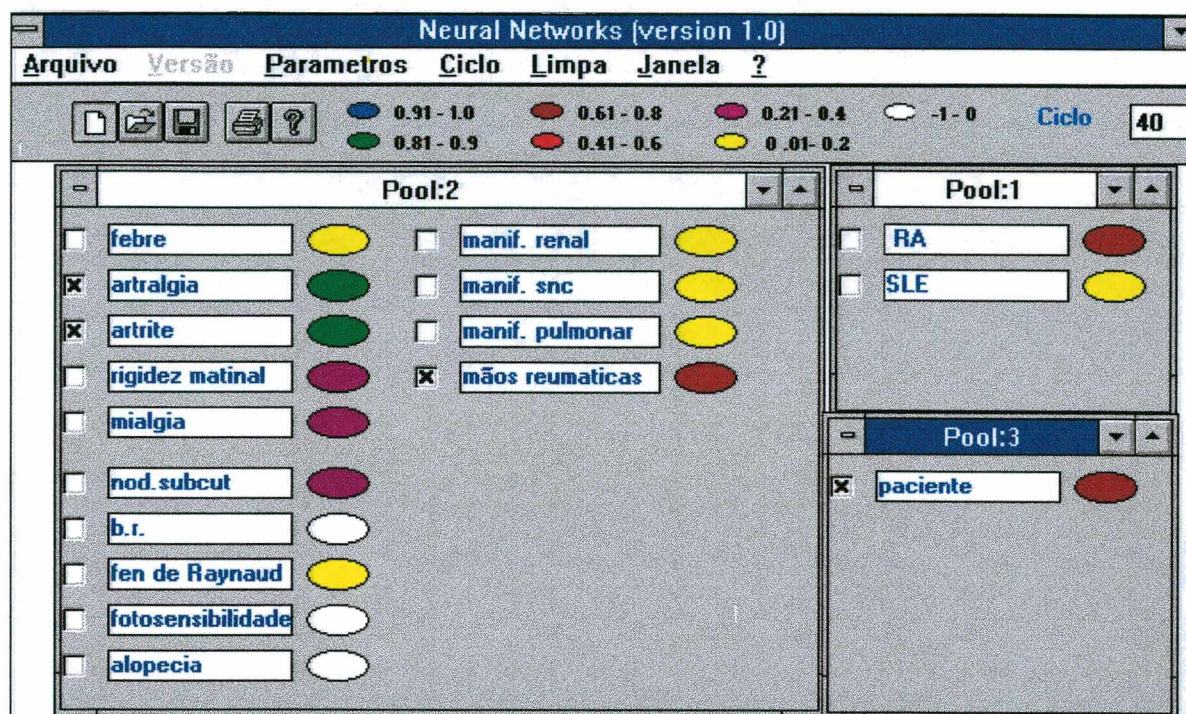


Figura 5.1 - Sist. "Reduzido", Ex. 1 - Paciente apresentando artralgia, artrite e mãos reumáticas após 40 ciclos.

Pode-se observar, após 40 ciclos, como mostra a figura 5.1, o sistema não é capaz de definir um diagnóstico, ou seja, o paciente poderá apresentar tanto RA como SLE, apesar de haver uma diferença no valor do nível de ativação de cada doença. Isto também pode ser observado no gráfico do transitório dos níveis de ativação, conforme figura 5.2.

As figuras 5.3, 5.4 e 5.5 apresentam o transitório dos níveis de ativação para as doenças, mas considerando em cada caso (figura), a introdução, no grupo de Casos, de casos reais clínicos para cada doença.




Figura 5.2 - Sist. "Reduzido", Ex. 1 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.




Figura 5.3 - Sist. "Reduzido", Ex. 1 - Introdução de um caso real para cada doença.




Figura 5.4 - Sist. "Reduzido", Ex. 1 - Introdução de três casos reais para cada doença.




Figura 5.5 - Sist. "Reduzido", Ex. 1 - Introdução de seis casos reais para cada doença.

Com a introdução de casos reais clínicos, observa-se que houve uma melhora no desempenho da rede, que chega, assim, à um diagnóstico final.

Exemplo 2

Neste exemplo, foi considerado um paciente apresentando os sintomas mialgia, manifestação renal e rigidez matinal, conforme visto na figura 5.6. Observa-se, novamente, que não existem casos reais conhecidos neste estágio da simulação.

Pode-se observar, após 40 ciclos, como mostra a figura 5.6, o sistema, de novo, não é capaz de definir um diagnóstico, ou seja, o paciente poderá apresentar tanto RA como SLE, apesar de haver uma diferença no valor do nível de ativação de cada doença. Isto também pode ser observado no gráfico do transitório dos níveis de ativação, conforme figura 5.7.

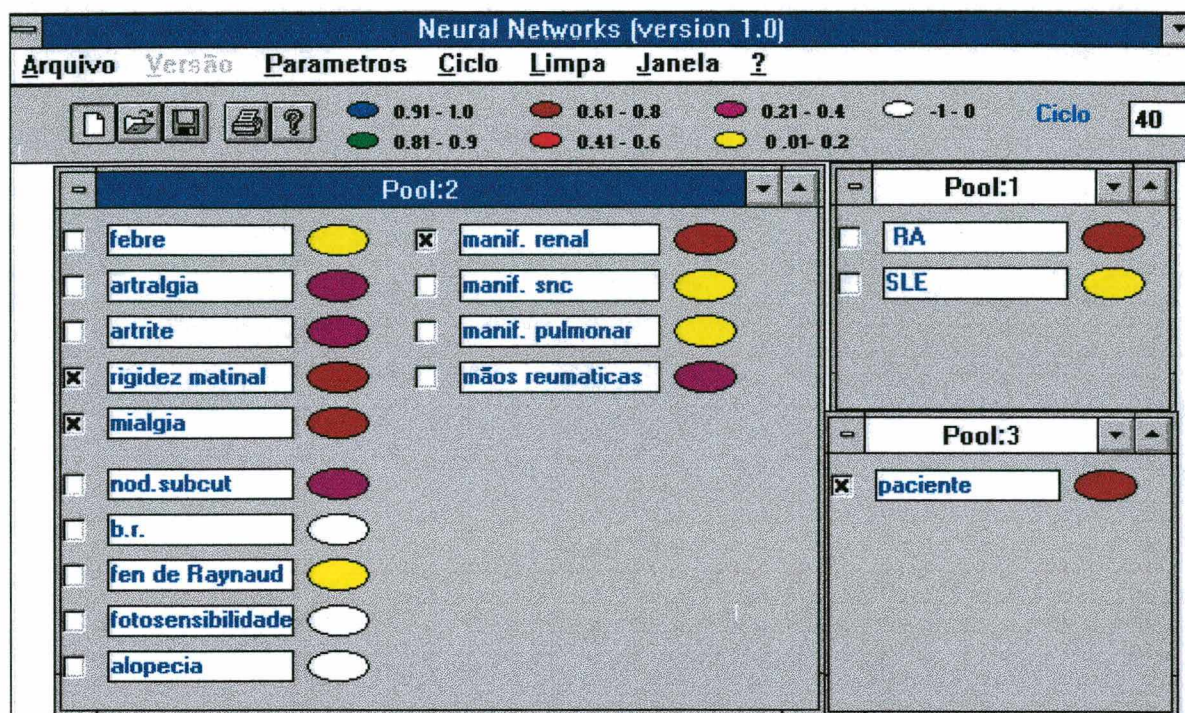


Figura 5.6 -Sist. "Reduzido", Ex. 2 - Paciente apresentando os sintomas mialgia, manifestação renal e rigidez matinal após 40 ciclos.




Figura 5.7 - Sist. "Reduzido", Ex. 2 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.

As figuras 5.8, 5.9 e 5.10 apresentam o transitório dos níveis de ativação para as doenças considerando, em cada caso (figura), a introdução, no grupo de Casos, de casos reais clínicos para cada doença.




Figura 5.8 - Sist. "Reduzido", Ex. 2 - Introdução de dois casos reais para cada doença.




Figura 5.9 - Sist. "Reduzido", Ex. 2 - Introdução de quatro casos reais para cada doença.




Figura 5.10 - Sist. "Reduzido", Ex. 2 - Introdução de seis casos reais para cada doença.

Com a introdução de casos reais clínicos, observa-se que houve uma melhora no desempenho da rede, que chega, mais uma vez, a um diagnóstico final.

Exemplo 3

Neste exemplo, foi considerado um paciente apresentando os sintomas artralgia, artrite e erupção tipo borboleta, conforme visto na figura 5.11. Novamente, não existem casos reais conhecidos neste estágio da simulação.

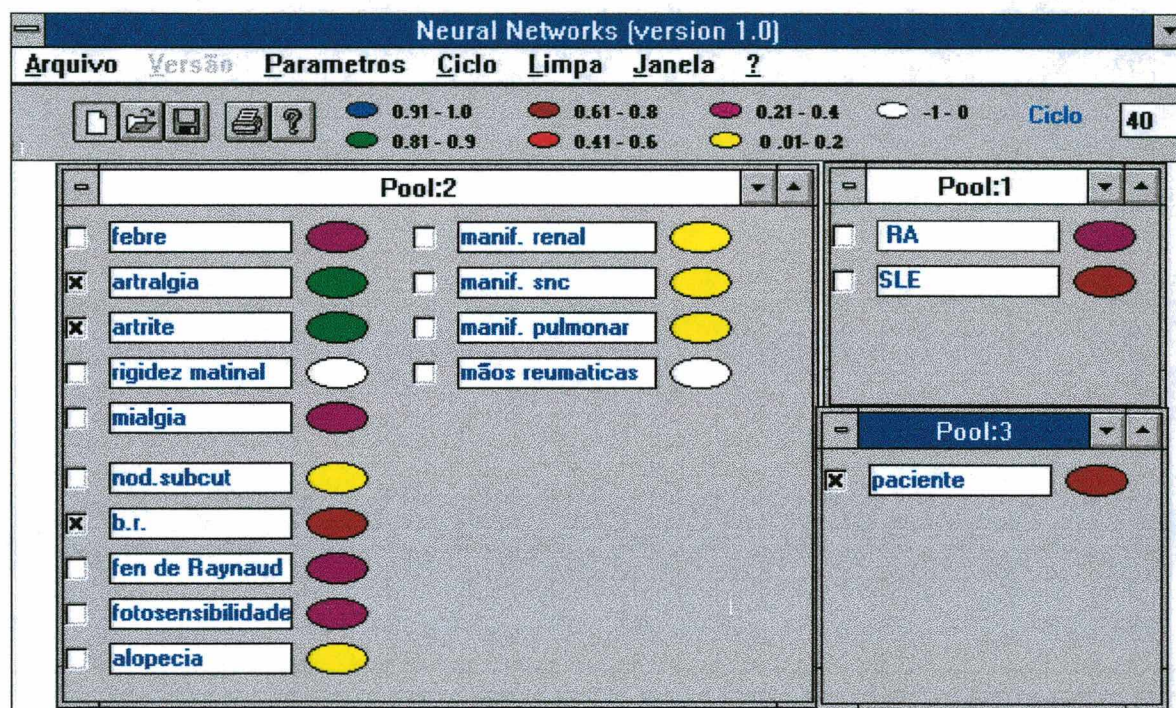


Figura 5.11 - Sist. "Reduzido", Ex. 3 - Paciente apresentando os sintomas artralgia, artrite e erupção tipo borboleta após 40 ciclos.

Pode-se observar, após 40 ciclos, como mostra a figura 5.6, o sistema não é capaz de definir um diagnóstico, ou seja, o paciente poderá apresentar tanto RA como SLE, apesar de haver uma diferença no valor do nível de ativação de cada doença. Isto também pode ser observado no gráfico do transitório dos níveis de ativação, conforme figura 5.12.




Figura 5.12 - Sist. "Reduzido", Ex. 3 -Transitório dos níveis de ativação sem a introdução de casos reais clínicos.

As figuras 5.13, 5.14 e 5.15 apresentam o transitório dos níveis de ativação para as doenças mas, considerando, de novo, a introdução, no grupo de Casos, de casos reais clínicos para cada doença.




Figura 5.13 - Sist. "Reduzido", Ex. 3 - Introdução de dois casos reais para cada doença.




Figura 5.14 - Sist. "Reduzido", Ex. 3 - Introdução de quatro casos reais para cada doença.




Figura 5.15 -Sist. "Reduzido", Ex. 3 - Introdução de seis casos reais para cada doença.

Com a introdução de casos reais clínicos, observa-se que houve uma melhora no desempenho da rede, chegando a um diagnóstico.

5.3 - Simulações - Sistema "Completo"

Neste item o SE “completo” é estudado. Ou seja, utiliza-se 4 doenças (RA, SLE, PA e AG), 17 sintomas (febre, artralgia, artrite, rigidez matinal, mialgia, nódulo subcutâneo, erupção tipo borboleta, fenômeno de Raynaud, fotosensibilidade, manifestação renal, manifestação no sistema nervoso central, manifestação pulmonar e mãos reumáticas, lesão pisoriática, tophi e podagra) e 24 casos reais clínicos, 6 para cada doença.

Para implementar esta versão utilizou-se 3 grupos sendo um para as doenças, um para sintomas e um para os casos clínicos diagnosticados.

O grupo de doenças contém quatro neurônios, sendo, Artrite Reumatóide, Lúpus Eritematoso, Atrite de Gota e Artrite Psoriática. As conexões entre estes neurônios são inibitórias, mas não totalmente inibitórias, pois um paciente pode ter mais de uma doença ao mesmo tempo. A matriz que representa esta conexão está representada abaixo:

$$D/D = \begin{vmatrix} 0 & -0.9 & -0.9 & -0.9 \\ -0.9 & 0 & -0.9 & -0.9 \\ -0.9 & -0.9 & 0 & -0.9 \\ -0.9 & -0.9 & -0.9 & 0 \end{vmatrix}$$

O grupo de sintomas, é constituído de 17 neurônios, cada um correspondendo a um sintoma. A matriz que representa os sintomas/sintomas (S/S), é uma matriz nula 17x17, representando ignorância total entre os sintomas.

O grupo que representa os casos reais clínicos diagnosticados, é constituído de 25 neurônios que são: Paciente, Anne, Helen, Mary, Susan, Lucy, Carol, Pat, Jackie, Sue, Beth, Linda, Mag. Marilyn, Gill, Jeanny, Meryl, Rita, Ruth, Sara, Laura, Barbara, Jane e Evelyn. A conexão entre eles é totalmente inibitória, significando que cada caso está isolado de outro caso, levando assim a competição entre os neurônios pertencentes a este grupo de casos clínicos.

A diagonal principal da matriz de casos/casos é nula, e os demais valores, são totalmente inibitórios.

Com relação as conexões entre os diferentes grupos, estas são representadas utilizando valores fuzzy.

As conexões entre as doenças e os sintomas são dadas por:

$$D/S = \begin{vmatrix} 0.4 & 1 & 0.9 & 0.7 & 0.6 & 0.8 & -1 & 0.2 & 0 & -0.9 & 0.3 & 0.2 & 0.2 & 0.6 & 0.1 & -0.9 & -0.9 \\ 0.6 & 0.9 & 0.6 & -0.9 & 0.6 & 0 & 0.8 & 0.5 & 0.6 & 0.8 & 0.4 & 0.4 & 0.2 & -0.9 & 0 & -0.9 & -0.9 \\ 0.4 & 1 & 1 & 0.7 & 0.4 & -0.9 & -0.9 & -0.9 & 0 & -0.5 & -0.5 & -0.5 & 0 & -0.5 & 1 & -0.9 & -0.9 \\ 0.4 & 0.9 & 0.9 & 0 & 0.1 & -0.9 & -0.9 & -0.9 & 0 & -0.5 & 0.1 & 0.1 & 0 & 0.5 & 0 & 1 & 0.8 \end{vmatrix}$$

Entre os grupos de doenças e casos, os valores das conexões recebem apenas valores 1 e 0.

Finalmente, as conexões entre sintomas e casos são dadas pela seguinte matriz:

S/C=

0	05	0	05	05	05	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
05	0	05	0	05	05	05	0	05	05	05	09	05	05	05	05	05	05	05	05	05	05	05
0	09	05	0	05	05	0	05	05	05	05	0	05	05	05	0	05	05	05	05	05	0	05
0	0	0	05	0	05	0	0	0	0	0	0	0	05	0	05	0	0	05	0	0	0	0
0	0	0	09	0	0	0	0	05	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	05	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	09	0	09	0	0	09	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	05	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	05	09	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	05	0	0	0	0	0	0	0	0	05	0	0	0	0	0	0	0	0	0	0	09	0
0	0	0	0	05	0	0	0	0	0	05	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	09	05	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	09	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	09	09	09	09	09	09	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	09	09	09	09	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	09	09	09	09	0	09

Exemplo 1

Neste exemplo, foi considerado um paciente apresentando os sintomas artralgia, artrite e tophi, conforme visto na figura 5.16. Observa-se, também, que não existem casos reais conhecidos neste estágio da simulação.

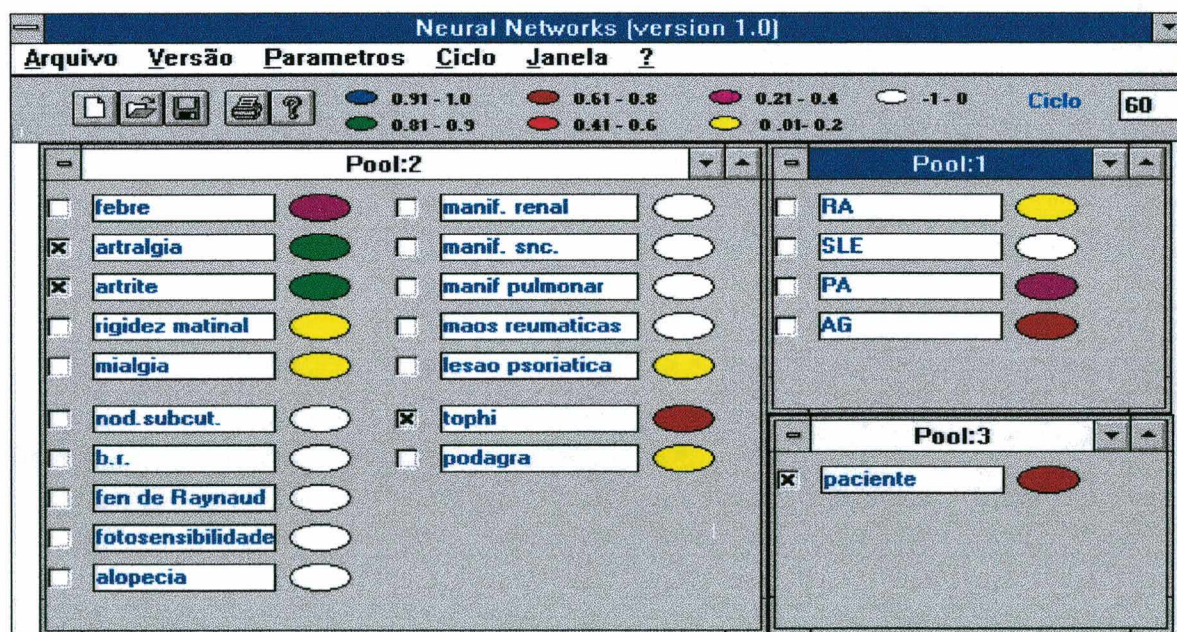


Figura 5.16 - Sist. "completo", Ex.1 - Paciente apresentando os sintomas artralgia, artrite e tophi após 60 ciclos.

Pode-se observar, após 60 ciclos, como mostra a figura 5.16, o sistema não é capaz de definir um diagnóstico, ou seja, o paciente poderá apresentar tanto RA, SLE,

AG ou PA apesar de haver uma diferença no valor do nível de ativação de cada doença. Isto também pode ser observado no gráfico do transitório dos níveis de ativação, conforme figura 5.17.




Figura 5.17 - Sist. "completo", Ex.1 - Transitório do nível de ativação sem a introdução de casos reais clínicos.

As figuras 5.18, 5.19 e 5.20 apresentam o transitório dos níveis de ativação para as quatro doenças considerando em cada caso (figura), a introdução, no grupo de Casos, de casos reais clínicos para cada doença.




Figura 5.18 - Sist. "completo", Ex.1 - Introdução de dois casos reais para cada doença.




Figura 5.19 - Sist. "completo", Ex.1 - Introdução de quatro casos reais para cada doença.




Figura 5.20 - Sist. "completo", Ex.1 - Introdução de seis casos reais para cada doença.

Com a introdução de casos reais clínicos, observa-se que houve uma melhora no desempenho da rede, que chega, assim, à um diagnóstico final.

Exemplo 2

Aqui, foi considerado um paciente apresentando os sintomas artralgia, artrite e mãos reumáticas, conforme mostra a figura 5.21. Não existem casos reais conhecidos neste estágio da simulação.

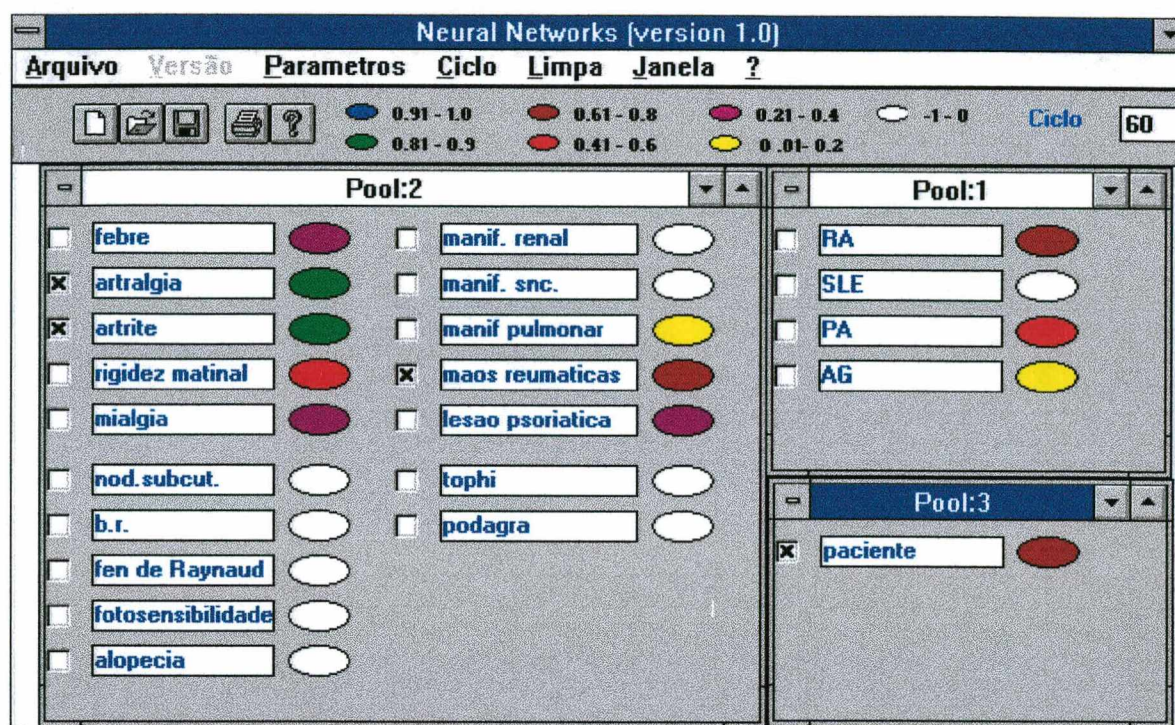


Figura 5.21 - Sist. "completo", Ex.2 - Paciente apresentando os sintomas artralgia, artrite e mãos reumáticas após 60 ciclos.

Observa-se após 60 ciclos, conforme mostra a figura 5.21, que o sistema não é capaz de definir um diagnóstico, apesar de haver uma diferença no valor do nível de ativação de cada doença. Isto também pode ser observado no gráfico do transitório dos níveis de ativação, conforme figura 5.22.




Figura 5.22 - Sist. "completo", Ex.2 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.

As figuras 5.23, 5.24 e 5.25 apresentam o transitório dos níveis de ativação para as doenças considerando em cada caso (figura), a introdução, no grupo de Casos, de casos reais clínicos para cada doença.




Figura 5.23 - Sist. "completo", Ex.2 - Introdução de dois casos reais para cada doença.




Figura 5.24 - Sist. "completo", Ex.2 - Introdução de quatro casos reais para cada doença.

Com a introdução de casos reais clínicos, observa-se que, a rede chega a um diagnóstico.




Figura 5.25 - Sist. "completo", Ex.2 - Introdução de seis casos reais para cada doença.

Exemplo 3

Este exemplo, mostra um paciente apresentando os sintomas artrite, artralgia e lesão psoriática, conforme figura 5.26. De novo não existem casos reais conhecidos neste estágio da simulação.

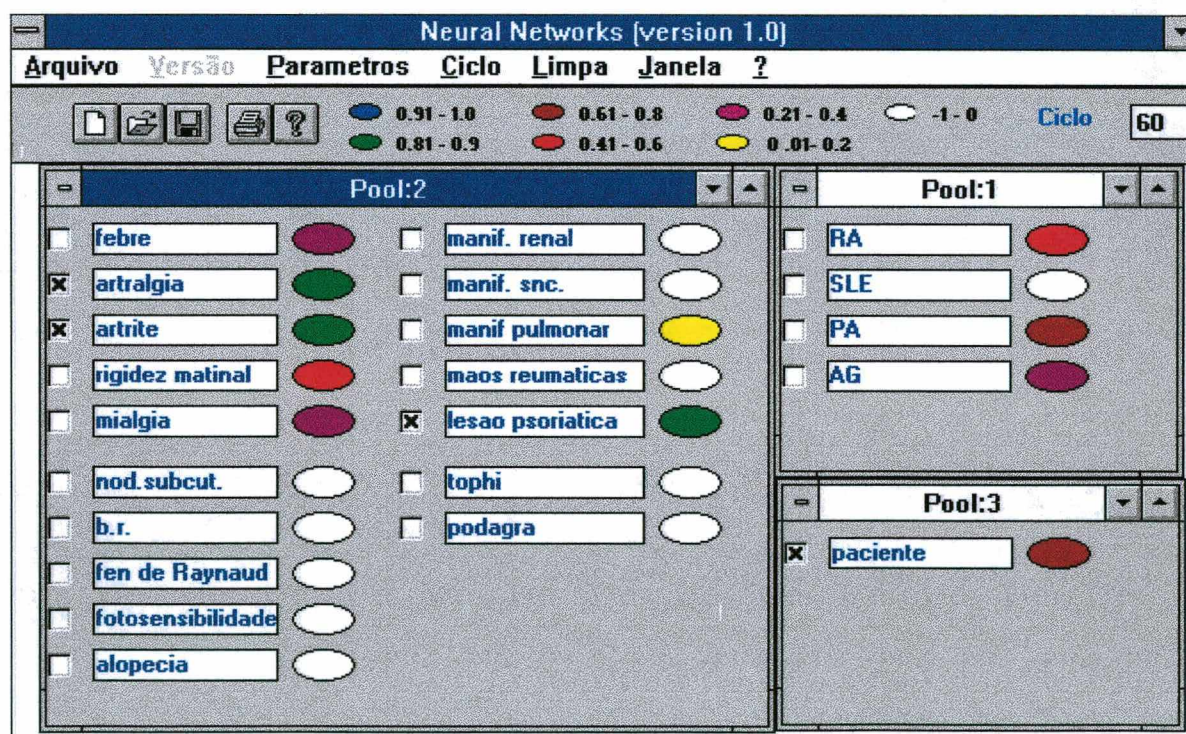


Figura 5.26 - Sist. "completo", Ex.3 - Paciente apresentando os sintomas artrite, artralgia e lesão psoriática após 60 ciclos.

Pode-se observar, após 60 ciclos, conforme a figura 5.26, que o sistema não é capaz de definir um diagnóstico. Isto também pode ser observado no gráfico do transitório dos níveis de ativação, conforme figura 5.27.




Figura 5.27 - Sist. "completo", Ex.3 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.

Novamente as figuras 5.28 e 5.29 apresentam o transitório dos níveis de ativação para as doenças considerando no grupo de Casos, a introdução de casos reais clínicos para cada doença.




Figura 5.28 - Sist. "completo", Ex.3 - Introdução de três casos reais para cada doença.




Figura 5.29- Sist. "completo", Ex.3 - Introdução de seis casos reais para cada doença.

Observa-se, então que houve uma melhora no desempenho da rede, chegando à um diagnóstico final.

Exemplo 4

Neste exemplo, o paciente apresenta os sintomas artrite, artralgia e erupção tipo borboleta, conforme visto na figura 5.30. Mais uma vez não existem casos reais conhecidos neste estágio da simulação.

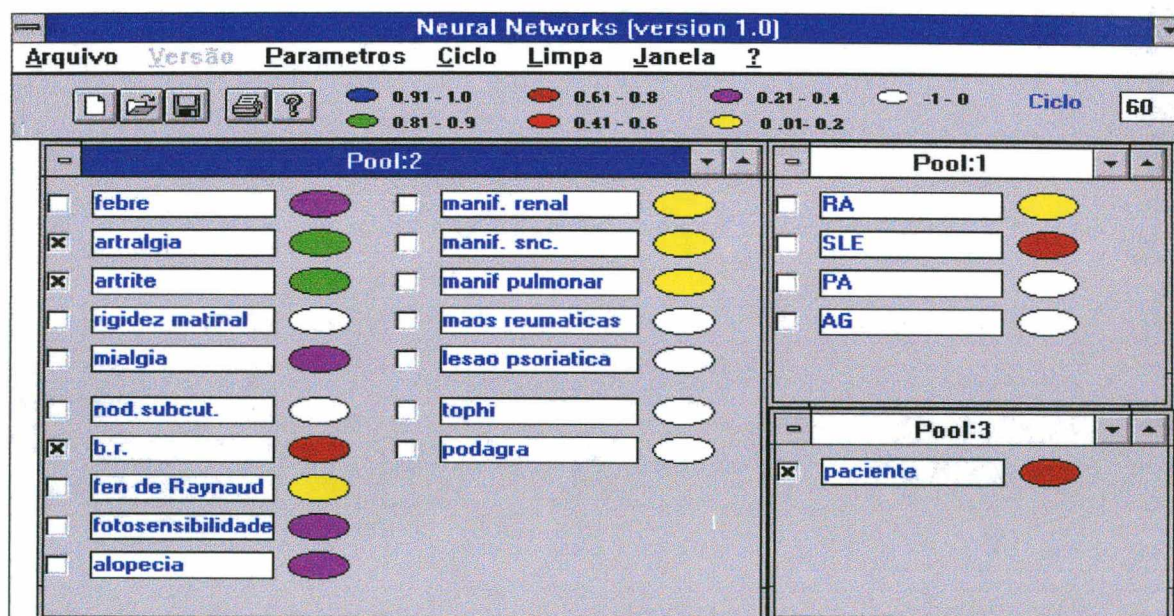


Figura 5.30 - Sist. "completo", Ex.4 - Paciente apresentando os sintomas artrite, artralgia e erupção tipo borboleta após 60 ciclos.

Pode-se observar, após 60 ciclos, como mostra a figura 5.30, o sistema não é capaz de definir um diagnóstico, ou seja, o paciente poderá apresentar tanto RA, SLE,

AG ou PA apesar de haver uma diferença no valor do nível de ativação de cada doença. Isto também pode ser observado no gráfico do transitório dos níveis de ativação, conforme figura 5.31.




Figura 5.31 - Sist. "completo", Ex.4 - Transitório dos níveis de ativação sem a introdução de casos reais clínicos.

As figuras 5.32, 5.33 e 5.34 apresentam o transitório dos níveis de ativação para as doenças, mas considerando, em cada caso (figura), a introdução, no grupo de Casos, de casos reais clínicos para cada doença.




Figura 5.33 - Sist. "completo", Ex.4 - Introdução de dois casos reais para cada doença.




Figura 5.34 - Sist. "completo", Ex.4 - Introdução de quatro casos reais para cada doença.




Figura 5.35 - Sist. "completo", Ex.4 - Introdução de seis casos reais para cada doença.

Com a introdução de casos reais clínicos, observa-se que a rede chega, assim, a um diagnóstico final.

CAPÍTULO 6: DISCUSSÕES E CONCLUSÕES

Conforme exposto na Introdução deste trabalho, dois são os objetivos perseguidos. Primeiro o estudo do aprendizado baseado em casos em redes tipo IAC. Segundo o desenvolvimento de um sistema computacional para a implementação do referido modelo que resolva as limitações encontradas no pacote de *software* original de Rumelhart.

Com relação ao primeiro objetivo, pode-se dizer que o conjunto de simulações realizadas (algumas delas mostradas no Capítulo 5) confirmaram a conjectura inicial de que a presença, na estrutura da rede, de um grupo (ou pool) de casos reais, diagnosticados por um especialista médico, melhora o desempenho na direção de um diagnóstico.

Ou seja, considerando uma implementação de rede com grupos representativos apenas dos sintomas e das doenças e as conseqüentes conexões das relações sintomas/doenças, o sistema não é, muitas vezes, capaz de definir um diagnóstico. Nos casos em que tal rede consegue chegar à uma resposta, a diferença, muitas vezes, entre os níveis de ativação relativos aos neurônios representativos das doenças, não é significativo.

Quando da introdução do grupo representativo dos casos reais clínicos, é observado que, quanto maior o número de casos representativos de cada doença, mais rapidamente a rede define um diagnóstico. No entanto, faz-se necessário observar que, se os casos não forem bem escolhidos e não existirem em número aproximadamente igual para cada doença, o sistema poderia ficar polarizado o que levaria à um diagnóstico errôneo.

Por outro lado, confirma-se a conjectura segunda de que o sistema utiliza uma abordagem de CBR (*Case Based Reasoning*). A rede, além de considerar as relações sintomas/doenças, procura um (ou mais) caso (s), na "base de casos", que apresente uma maior similaridade com o caso em questão. Ou seja, pode-se afirmar, "grosso modo", que a rede utiliza-se de casos anteriores para interpretar ou resolver novos casos e construir uma nova solução.

Com relação ao segundo objetivo, pode-se dizer que o sistema computacional desenvolvido apresenta uma série de características desejáveis em sistemas *user-friendly*, quais sejam:

- a) uma boa interface com o usuário pelo fato de utilizar ambiente Windows;
- b) a facilidade na definição da estrutura da rede, no sentido da definição dos grupos, dos neurônios por grupo e do nível de ativação inicial de cada neurônio;
- c) no caso da matriz sináptica, para os modelos de Rumelhart e Grossberg, ela é gerada automaticamente. E no modelo de Azevedo, o sistema apresenta facilidades para a introdução dos valores fuzzy relativos a cada conexão;
- d) o sistema permite facilmente salvar e ler arquivos contendo a estrutura da rede e a matriz de pesos sinápticos,
- e) o sistema é flexível, o suficiente, para permitir a introdução de outros módulos contendo modificações nos modelos supracitados ou na implementação de outros modelos de rede;
- f) a geração de gráficos é automática a partir da simples definição de quais neurônios se deseja o transitório dos níveis de ativação.

Finalizando, sugere-se como uma possível continuação deste estudo, na direção da utilização das redes IAC para a implementação de Sistemas Especialistas, o desenvolvimento de um algoritmo de aprendizagem de forma que as relações (ou seja, os pesos das conexões) entre os diferentes grupos não sejam "impostas", mas sim determinadas.

BIBLIOGRAFIA

[Appol90] - APPOLONI, B., Avanzini, G., Cesa-Bianchi, N., Ronchini, G., *Diagnosis of Epilepsy via Backpropagation. In Proceedings of IJCNN-90 - International Joint Conference on Neural Networks*, volume 2, pag. 571-574, Washington, USA, 1990.

[Arb87] - ARBIB, *Brains Machines and Mathematics*. Springer-Verlag, 1987.

[Azev91a] - DE AZEVEDO, F.M., Barreto, J.M., Eppecht, L.R., Lima, W.C., Zanchin, C.I., *A Neural Network Approach for Medical Diagnosis. In Mini and Microcomputers in Medicine and Health Care91*, p.78-81, Long Beach, Ca, USA, 1991.

[Azev91b] - DE AZEVEDO, F.M., Barreto, J.M., Eppecht, E.K., Epprecht, L.R., Zanchin, C.I., *Two Approaches in cade-based connectionist expert systems. In Proceedings of the IASTED International Conference, on Artificial Intelligence Applications and Neural Networks*, p.13-17, Zurich, Switzeland, 1991.

[Azev93] - DE AZEVEDO, *Contribution to the Study of Neural Networks in Dynamical Expert Systems*. Tese de Doutorado, Institut d'Informatique, FUNDP, Namur, Belgium, 1993.

[Baen92] - DE BAENST-VANDENBROUNCK, A., de Azevedo, F.M., Barreto, J.M., *Is a Neural Network Object-Oriented? A Look at an Application in Medical Decision Support*. In 13th Internacional Congree on Cybernetics, Bélgica, 1992.

[Bar96] - BARRETO, J.M., *Conexionismo e Resolução de Problemas*. Titular professor constest dissertation, Universidade Federal de Santa Catarina, Departamento de Informática e Estatística, Florianópolis, SC, 1996.

[Bar93] - BARRETO, J.M., de Azevedo, F.M., *Connectionist expert systems as medical decision aid. Artificial Intelligence in Medicine*, 1993.

[Boone90] - BOONE, J., Sigillito V., Shaber G., *Neural Network inRadiology - An Introduction and Evaluation in a Signal Detection Task. Med. Phys.*, 17(2):234-241, 1990.

- [Bounds90] - BOUNDS, D., Lloyd, P., Mathew, B., *A Comparision of Neural Network and Other Pattern Recognition Approaches to the Diagnosis of Low Back Disorders. Neural Networks*, 3(3):583-592, 1990.
- [Bra97] - BRASIL, L.M., de Azevedo, F.M., Barreto, J.M., *A hybrid expert architecture for medical diagnosis. Third International Conference on Artificial Neural Networks and Genetic Algorithms - ICANNGA97*, Norwich, UK, April, 1997, Aceito.
- [Cau91] - CAUDILL, Maureen, *Expert Networks*, Byte, October 1991.
- [Cof89] - COFFEY, D., Banks, G. *A Connectionist Visual Field Analyser. In Proceedings of 13th Ann. Symp. Comput. Appl. Med. Care*, p. 276-282, New York, 1989, IEEE Press.
- [Coh83] - COHEN, M., Grossberg, I.S., *Absolute Stability of Global Pattern formation and Parallel Memory Storage by Competitive Neural Networks*. In *IEEE Transactions on Systems, Man and Cybernetics*, p. 815-826, 1983.
- [Day90] - DAYHOFF, J., *Neural Network Architectures - An Introduction*. Van Nostrand Reinhold, 1990.
- [Dud79] - DUDA, R.O., Hart, P.E., Konolige, K., Roboh, R.A., *Computer Based Consultant for Mineral Exploration*, Relatórios Técnicos, SRI International, 1979.
- [Eber90] - EBERHART, r., Dobbins, R., *Neural Networks versus Bayesian Diagnosis of Appendicitis. In Proceedings of 12th Ann. Conf. IEEE Engineer Med. Biol. Soc.*, Philadelphia, PA, USA, 1990.
- [Fei88] - FEIGENBAUM, E., at.al, *The Rise of the Expert Company*, New York, Times Books, 1988.
- [Gal88] - GALLANT, S.J., *Connectionist Expert Systems Communication od the ACM*, 1988.
- [Garcia92] - GARCIA, R., *Técnicas de Inteligência Artificial Aplicadas ao Apoio a Decisão Médica na Especialidade de Anestesiologia. Tese de Doutorado na Universidade Federal de Santa Catarina - UFSC, Florianópolis, SC*, 1992.

- [Garcia90] - GARCIA, R., Lima, W. C., Duarte, D., *Expert System for Evaluation and Proposal of Anesthetic Procedures with Neural Networks. In Proceedings Intern. Conf Systems Engineer*, Las Vegas, USA, July 1990
- [Har91] - HARRISON, B., Marshall, S., Kennedy, R., *A Connectionist Aid to the Early Diagnosis of Myocardial Infarction. In Proceeding Of Third European Conf. Artificial Intelligence in Medicine, Maastricht*, The Netherlands, June 1991.
- [Harm88] - HARMON, P., King, D., *Sistemas Especialistas, A Inteligência Artificial chega ao mercado*, São Paulo: Editora Campus, 1988.
- [Hart90] - HART, A.W.J., *Evaluating black-boxes as medical decision and issues arising from a study of neural networks*, Med. Inform., 1990.
- [Hay94] - HAYKIN, S., *Neural Networks - A Comprehensive Foundation. IEEE Computer Society Press*, IEEE Press, 1994.
- [Heb49] - HEBB, D.O., *The Organization of Behavior*. John Wiley, New York, 1949.
- [Hell91] - HELLER, M., *AI In Practice*, Byte Mag., Jan/1991.
- [Hof81] - HOFSTADTER, D.R., *The Mind's I*. Penguin Books, New York, 1981.
- [Hudson88] - HUDSON, D., Cohen, M., Anderson, M., *Determination of Testing Efficacy in Carcinoma of the Lung Using a Neural Network Model. In Proceeding of 12th Ann. Symp. Comput. Appl. Med. Care*, p. 252-255, New York, USA, 1988. IEEE Press.
- [Kart96] - KARTALOPOULOS, S.V., *Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications*. IEEE Press, Inc., New York, 1996.
- [Koh88] - KOHONEN, T., *Self- Organization and Associative Memory*. Springer-Verlag, New York, 1988.
- [Kosk88] - KOSKO, B., *Bidirectional associative memories. IEEE Transactions on Systems, Man and Cybernetics*, v.18, n.1, p 49-60, 1988.
- [Kov96] - KOVACS, Z.L., *Redes Neurais Artificiais - Fundamentos e Aplicações*. Edição Acadêmica, São Paulo, 1996.
- [Law92] - LAWRENCE, J., *Introduction to Neural Networks and Expert Systems*, Nevada City (California): California Scientific Software, 1992.

- [Lin97] - LINARES, K.S.C., "Sistema Especialista Nebuloso para Diagnóstico Médico". tese de Mestrado, Universidade Federal de Santa Catarina - UFSC, Engenharia Biomédica, 1997.
- [Lop95] - LOPES, H.S., Coutinho, M.S., Lima, W.C., *Using Genetic Algorithms for Qualitative Improvement of Clinical Diagnosis Abilities. VI IFSA World Congress*, São Paulo, august 24-28, 1995, Proceedings V.I, pp:161-164.
- [Mach92] - MACHADO, R.J., Rocha, A.F., *A hybrid architecture for fuzzy connectionist expert systems. In: Hybrid for Intelligent Systems*, p. 135-152, CRC Press, Inc. Flórida, USA, 1992.
- [Mar90] - MAREN, A.J., *Multilayer Feedforward Neural Networks I: Delta Rule Learning*, In:- Harston, C.T., PAP, R.M. (eds), *Handbook of Neural Computing Applications*, San Diego (California): Academic Press, Inc., 1990.
- [McC43] - McCUULLOCH, W., Pitts, W., *A Logical Calculus of the Ideas Immanent in Nervous Activity* - Bulletin of Mathematical Biophysics, 1943.
- [McMil89] - McMILLAN, M., Walter, D., *Automated Medical Student - A Computational Model of Skill Acquisition and Expert Performance. In Proceedings of Sec. Ann. IEEE Simp. Comput.-Based Med. Syst.*, p. 108-113, Washington, DC, 1989. IEEE Computer Soc. Press.
- [Min69] - MINSKY, M.L., Papert, S.A., *Perceptrons: An Introduction to Computational Geometry*. The MIT Press, 3rd impression (modificado) 1988, 1969.
- [Muls92] - MULSANT, B., Servan-Schreiber, E., *A Connectionist Approach to the Study of Dementia*. In Proceedings of 12 th Ann. Symp. Comput. Appl. Med. Care, p. 245-250, New York, 1988. IEEE Press.
- [Nasc94] - NASCIMENTO JR., C.L., *Artificial Neural Networks in Control and Optimization*. PhD thesis, Control Systems Centre, University of Manchester, UK, 1994.
- [Nas95] - NASSAR, S.M., Lima, W.C., Barreto, J.M., *ISSMER: An Intelligent Statistical System for Medical Research, Thirteenth IASTED International Conference, Applied Informatics*, 21-23 Feb. 1995, IGLS, Austria, Proceedings pp: 37-40.

- [Niev90] - NIEVOLA, J.C., Lima, W.C., Barreto, J.M., *A system with dynamic processing. ISMM International Conference MICRO'90*, 22-24 May 1990, Montreal, Canada.
- [Ober89] - OBERMEIER, K.K., Barron, J.J., *Time to Get Fired Up*, Byte, August/1989.
- [Pass95] - PASSOLD, F., Garcia, R.O., *Hybrid Expert Systems in Anesthesiology for Critical Patients. ELECTRO'95 - XI Congresso Chileno de Ingenieria Electrica*, Punta Arenas, Chile, Nov. 13-17, 1995, Proceedings Vol. I, pp: H-001 a H006.
- [Park82] - PARKER, D., *Learning Logic. Invention Report, Stanford University, File 1, Office of Technology Licensing*, Stanford, Californ, 1982.
- [Pham89] - PHAM, K., Degoulet, P., *MOSAIC: Medical Knowledge Processing Based on a Macro-connectionist Approach to Neural Networks. In Proceedings 6th. World Conf. Medical Informatics*, p. 82-86, Amsterdam, 1989. North Holland.
- [Pe97] - PEREZ, R.L.C., "Sistema Especialista de Apoio à Decisão Médica com Metodologias de Aprendizagem Simbólica". Tese de Mestrado, Universidade Federal de Santa Catarina - UFSC, Engenharia Elétrica, 1997.
- [Ram95] - RAMIREZ, A.T., Lima, W.C., Barreto, J.M., Fernandez, J., *EPIIS: A Epilepsy Intelligent Instruction System Using Multi-Agent Society Paradigm. 38th Midwest Symposium on Circuits and Systems*, Rio de Janeiro, August, 13-16, 1995.
- [Rich93] - RICH, E., Knight, K., *Inteligência Artificial*. Makron Books, São Paulo, Brasil, segunda edição, 1993.
- [Rich84] - RICH, E., *Artificial Intelligence*. McGraw-Hill, New York, 1984.
- [Rois96] - ROISENBERG, M., *Emergência da Inteligência em Agentes Autônomos através de Modelos Inspirados na Natureza*, Exame de qualificação, UFSC, Engenharia Elétrica, 1996.
- [Rum86] - RUMELHART, D.E., Hinton, Williams, R.J., *Learning internal representations by error propagation. In: Parallel Distributed Processing*, v.1, 2: Foundations, MIT Press, Cambridge, Massachusetts, 1986.

- [Sab93] - SABBATINI, R.M.E., O Diagnóstico Médico por computadores, Informédica (Revista de Informática para médicos) Unicamp (São Paulo): Infor-Médica Apoio em Serviços S/C Ltda, Março/Abril, 1993.
- [Simp90] - SIMPSON, P.K., *Artificial Neural Systems - foundations, paradigms, applications and implementations. Neural Networks: Research and Applications*. Pergamon Press, Elmsford, N.Y., 1990.
- [Short76] - SHORTLIFFE, E.H., *Computer-based medical consultations: MYCIN*. Elsevier Science Publishers B.V., New York, USA, 1976.
- [Smith88] - SMITH, J., Everhart, J., Dickson, Knowler, W., Johannes, R., *Using the ADAP Learning Algorithm to Forecast the Onset of Diabetes Mellitus. In Proceedings of 12th Ann. Symp. Comput. Appl. Med. Care*. p. 261-265, New York, 1988. IEEE Press.
- [Souc89] - SOUCEK, J., *Neural and Concurrent Real-Time Systems (The Sixth Generation Computer)*, New York: John Wiley & Sons, 1989.
- [Ste89] - STEELS, L., *Connectionist Problem Solving - An IA Perspective. In Connectionism in Perspective*, p. 215-228. Elsevier Science Publishers B.V., The Netherlands, 1989.
- [Thr89] - THRIFT, P., *A Neural Network Model for Case Based Reasoning, Proceedings of a Workshop on Case Based Reasoning*, May 31 - June 2, Pensacola Beach, Flórida, USA, 1989, pp. 334-337 (Morgan Kaufmann).
- [Turb92] - TURBAN, E., *Expert Systems and Applied Artificial Intelligence*, Macmillan Publishing Company, Inc., New York, USA, 1992.
- [Werb74] - WERBOS, P., *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Ph.D. Thesis, Harvard University, Cambridge, Massachusetts, 1974.
- [Wid62] - WIDROW, B., *Generalization and Information Storage in Networks of Adaline Neurons*, em *Self-Organizing Systems*, 1962.
- [Yoon88] - YOON, Y., Peterson, L., Bergstresser, P., *DESKNET: The Dermatology Expert System with Knowledge-based Network. Neural Networks*, 1988.

[Yoshi89] - YOSHIDA, Y., Hayashi, Y., Imura, A., *A Connectionist Expert Systems for Diagnosing Hepatobiliary Disorders. In Proceedings of 6th World Conf. Med. Inform.* p. 116-120, Amsterdam, 1989. North Holland.

[Zad88] - ZADEH, L.A., *Fuzzy Logic*. Computer 1988.

[Zur92] - ZURADA, J., *Introduction to Artificial Neural Systems*. West Publishing Company, 1992.